

**UNIVERZITA KARLOVA V PRAZE**

**Přírodovědecká fakulta**

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Kristýna LIHANOVÁ

## **HODNOCENÍ POŠKOZENÍ LESNÍCH POROSTŮ S VYUŽITÍM DRUŽICOVÝCH A LIDAROVÝCH DAT**

### **ASSESSMENTS OF FOREST DAMAGE USING SATELLITE AND LIDAR DATA**

Diplomová práce

Vedoucí diplomové práce: RNDr. Přemysl Štych, Ph.D.

Praha 2013

### **Prohlášení**

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a že jsem všechny použité prameny řádně citovala.

Jsem si vědoma toho, že případné použití výsledků, získaných v této práci, mimo Univerzitu Karlovu v Praze je možné pouze po písemném souhlasu této univerzity.

Svoluji k zapůjčení této práce pro studijní účely a souhlasím s tím, aby byla řádně vedena v evidenci vypůjčovatelů.

V Praze dne 26. 8. 2013

.....  
Kristýna Lihanová

## **Poděkování**

Na tomto místě bych v první řadě ráda poděkovala vedoucímu mé diplomové práce RNDr. Přemyslu Štychovi, Ph.D. za věnovaný čas, ochotu a cenné rady. Dále děkuji Doc. RNDr. Jakubovi Langhammerovi, Ph.D., který je hlavním řešitelem projektu GAČR P209/12/0997, za vynaložení finančních prostředků z grantu na zakoupení dat leteckého laserového skenování, která byla pro tuto práci potřebná. Poděkování patří také Českému úřadu zeměměřickému a katastrálnímu za poskytnutí dat LLS i dat ostatních. V neposlední řadě patří velké díky také mojí rodině za podporu po celou dobu mého studia.

# Hodnocení poškození lesních porostů s využitím družicových a lidarových dat

## Abstrakt

Hlavním cílem této diplomové práce je vytvoření metodického postupu vhodného pro hodnocení poškození lesních porostů ve vybrané oblasti Národního parku Šumava při kombinaci multispektrálních a lidarových dat. Lesy v této oblasti jsou silně poškozené především díky přemnožení lýkožrouta smrkového a nacházejí se zde jak zdravé, tak poškozené lesní porosty. Na základě tohoto metodického postupu bude rozlišen o něco vyšší počet klasifikačních tříd (5 tříd), než který je uváděn ve většině odborné literatury. V práci byl použit zaostřený multispektrální snímek SPOT, multispektrální snímek Landsat a data z leteckého laserového skenování s malou hustotou bodů. Dílčím úkolem bylo z dat LLS získat informaci o výšce lesního porostu v podobě rastru. Lesní porosty byly klasifikovány metodou objektově orientované klasifikace, která zahrnovala nejprve segmentaci a poté tvorbu klasifikační báze. Do klasifikace vstupovala kromě spektrální informace také informace o průměrné výšce vegetace získaná z dat LLS. Lesy byly klasifikovány celkem do 5 tříd a přesnost obou klasifikací byla hodnocena pomocí chybové matice a kappa koeficientu. Klasifikace snímku SPOT dosáhla hodnoty kappa koeficientu 68,5 % a u klasifikace snímku Landsat se hodnota zvýšila na 72,3 %. Z výsledků klasifikace byly vytvořeny mapy zdravotního stavu lesních porostů v zájmovém území.

**Klíčová slova:** SPOT, Landsat, letecké laserové skenování, zdravotní stav lesa, kůrovec, OBIA, Šumava

## Abstract

The main objective of this thesis is to create a methodical procedure used for the evaluation of forest damage in the chosen area of the National Park Sumava, Czech Republic. In this work were combined the multispectral satellite data and data of airborne laser scanning. The forests in this area are heavily damaged mainly due to bark beetle outbreak. You can find here as healthy so damaged forests. Based on this methodology will be differentiated greater number of classes than I found in the literature. In this work was used pansharpened multispectral image SPOT, multispectral image Landsat and airborne laser scanning data with low density points. Another task was to get height information from ALS data in the form of grid. Forest stands were classified using object-oriented classification, which included at first segmentation and then creation of classification base. In classification entered spectral information and height information obtained from the ALS data. Forests were classified into 5 classes and accuracy of both classifications was evaluated using the error matrix and kappa coefficient. SPOT image classification reached kappa coefficient of 68,5 % and Landsat image classification reached kappa coefficient of 72,3 %. From the results of classification were created maps of forests health in the area of interest.

**Keywords:** SPOT, Landsat, airborne laser scanning, forest health assessment, bark beetle, OBIA, Sumava

# OBSAH

<b>OBSAH.....</b>	<b>6</b>
<b>PŘEHLED POUŽITÝCH ZKRATEK .....</b>	<b>8</b>
<b>SEZNAM OBRÁZKŮ A TABULEK.....</b>	<b>9</b>
<b>1 ÚVOD.....</b>	<b>11</b>
<b>2 LITERÁRNÍ REŠERŠE A ÚVOD DO PROBLEMATIKY .....</b>	<b>14</b>
2.1 Využití DPZ při mapování lesa.....	15
2.2 DPZ a zdravotní stav lesních porostů.....	16
2.3 Spektrální projev vegetace .....	22
2.3.1 Spektrální projev lesa napadeného kůrovcem.....	24
2.4 Data laserového skenování.....	25
2.5 Družicová data .....	25
2.5.1 Družicová data podle prostorového rozlišení.....	26
2.5.2 Pansharpening .....	27
2.6 Objektová klasifikace.....	28
2.6.1 Porovnání s pixelovou klasifikací .....	29
2.6.2 Segmentace .....	30
2.6.3 Klasifikace .....	33
<b>3 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ .....</b>	<b>35</b>
<b>4 DATA A METODIKA.....</b>	<b>37</b>
4.1 Použitá data .....	37
4.2 Použitý software.....	39
4.3 Předzpracování družicových snímků .....	39
4.4 Předzpracování dat LLS.....	40
4.5 Zpracování dat LLS .....	41
4.6 Stanovení klasifikačního systému .....	44
4.7 Objektově orientovaná klasifikace.....	45
4.7.1 Segmentace .....	46
4.7.2 Tvorba klasifikační báze .....	48

4.8	Hodnocení přesnosti klasifikace .....	53
<b>5</b>	<b>VÝSLEDKY .....</b>	<b>55</b>
5.1	Výsledky zpracování dat LLS a určení výšky vegetace.....	55
5.2	Výsledky objektové klasifikace .....	57
5.3	Výsledky hodnocení přesnosti klasifikace .....	59
<b>6</b>	<b>DISKUZE.....</b>	<b>63</b>
<b>7</b>	<b>ZÁVĚR.....</b>	<b>70</b>
	<b>SEZNAM POUŽITÝCH ZDROJŮ INFORMACÍ .....</b>	<b>72</b>
	<b>SEZNAM POUŽITÝCH ZDROJŮ DAT.....</b>	<b>79</b>
	<b>SEZNAM PŘÍLOH.....</b>	<b>80</b>

## PŘEHLED POUŽITÝCH ZKRATEK

<b>DEM</b>	<i>Digital Elevation Model</i> (digitální model terénu)
<b>DIMAP</b>	<i>Digital Image Map</i> (formát dat společnosti Spot Image)
<b>DPZ</b>	<i>Dálkový Průzkum Země</i>
<b>DSM</b>	<i>Digital Surface Model</i> (digitální model povrchu)
<b>ERTS</b>	<i>Earth Resource Technology Satellite</i> (původní název družice Landsat)
<b>ETM+</b>	<i>Enhanced Thematic Mapper Plus</i> (skener družice Landsat 7)
<b>IČ</b>	<i>Infračervené</i> (část elektromagnetického záření)
<b>LAI</b>	<i>Leaf Area Index</i> (index listové plochy)
<b>LiDAR</b>	<i>Light Detection and Ranging</i> (laserové skenování)
<b>LLS</b>	<i>Letecké Laserové Skenování</i>
<b>NDMI</b>	<i>Normalized difference moisture index</i> (normalizovaný dif. vlhkostní index)
<b>nDSM</b>	<i>Normalized Digital Surface Model</i> (normalizovaný digitální model povrchu)
<b>NDVI</b>	<i>Normalized Difference Vegetation Index</i> (normalizovaný dif. vegetační index)
<b>NP</b>	<i>Národní Park</i>
<b>OBIA</b>	<i>Object Based Image Analysis</i> (objektově orientovaná analýza obrazu)
<b>RGI</b>	<i>Red-Green Index</i>
<b>TC</b>	<i>Tasseled Cap</i> (transformace na vegetační komponenty)
<b>TM</b>	<i>Thematic Mapper</i> (skener družice Landsat 4 a 5)
<b>VHR</b>	<i>Very High Resolution</i> (velmi vysoké rozlišení)

## SEZNAM OBRÁZKŮ A TABULEK

Obr. 1: Křivka spektrálního chování vegetace .....	22
Obr. 2: Les napadený kůrovcem v červené a šedé fázi .....	23
Obr. 3: Ukázka původního a seg. obrazu metodou Chessboard segmentation .....	29
Obr. 4: Ukázka původního a seg. obrazu metodou Quadtree-based segmentation .....	30
Obr. 5: Ukázka původního a seg. obrazu metodou Multiresolution segmentation .....	30
Obr. 6: Situační mapka s umístěním zájmové oblasti v rámci správního členění ČR .....	35
Obr. 7: Původní a zaostřeny multispektrální snímek SPOT.....	39
Obr. 8: Nastavení parametrů funkce Project pro transformaci dat LLS.....	40
Obr. 9: Data LLS zobrazená v programu E3De .....	41
Obr. 10: Ukázka hustoty bodů LLS vygenerovaná v programu E3De .....	41
Obr. 11: Výřez DEM a DSM vygenerovaný v programu E3De .....	42
Obr. 12: Výřez normalizovaného digitální modelu povrchu (nDSM) .....	43
Obr. 13: Přehled klasifikačních tříd vytvořený v programu eCognition.....	44
Obr. 14: Ukázka segment. snímku SPOT s měřítkovým parametrem 20, 30 a 40.....	45
Obr. 15: Segment. snímku SPOT s vysokou a naopak nízkou váhou tvarového kritéria .....	46
Obr. 16: Výřez z výsledné segmentace snímku SPOT (vlevo) a Landsat (vpravo) .....	47
Obr. 17: Ukázka nastavení prahové hodnoty indexu RGI v panelu Feature View .....	48
Obr. 18: Vymezení třídy 1 pouze na základě indexu RGI na snímku SPOT .....	49
Obr. 19: Vymezení třídy 1 na základě indexu RGI a informací o výšce .....	50
Obr. 20: Vymezení třídy 2 na základě indexu RGI a informací o výšce .....	50
Obr. 21: Vymezení třídy 3 na základě indexu RGI a informace o výšce.....	51
Obr. 22: Ukázka poškozeného lesa na ortofotu a v rastru nDSM .....	55
Obr. 23: Ukázka zdravého lesa na ortofotu a v rastru nDSM .....	55
Obr. 24: Výřez průměrné výšky vegetace (vlevo) a ortofota (vpravo) .....	56
Obr. 25: Ukázka oblasti působící rozdílně na ortofotu z roku 2005 a v rastru nDSM.....	63
Obr. 26: Ukázka stejné oblasti na ortofotu z roku 2011 a v rastru nDSM .....	64
Tab. 1: Přehled spektrálních pásem družice SPOT 5 .....	37
Tab. 2: Přehled spektrálních pásem družice Landsat 5 TM .....	37
Tab. 3: Hodnoty parametrů použité při multiměřítkové segment. snímků SPOT a Landsat .....	47



Tab. 4: Přehled výsledků objektově orientované klasifikace snímku SPOT .....	57
Tab. 5: Přehled výsledků objektově orientované klasifikace snímku Landsat.....	58
Tab. 6: Chybová matice výsledné objektové klasifikace snímku SPOT.....	58
Tab. 7: Uživatelská, zpracovatelská, celková přesnost a kappa koeficient (SPOT).....	59
Tab. 8: Chybová matice výsledné objektové klasifikace snímku Landsat.....	60
Tab. 9: Uživatelská, zpracovatelská, celková přesnost a kappa koeficient (Landsat).....	60
Graf 1: Přesnost jednotlivých tříd při klasifikaci snímků SPOT a Landsat .....	67

# 1 ÚVOD

Lesy představují velmi důležitou součást životního prostředí a jako takové plní hned několik funkcí zároveň. Kromě toho, že jsou významným zdrojem kyslíku, plní také funkci zásobárny spodní vody. Ochranná funkce lesa spočívá ve zpevnění půdy a zabránění její erozi a sesuvům. Lesy blízké původnímu druhovému složení tvoří důležitý krajinný prvek s vysokou biodiverzitou a nelze opomenout ani významnou rekreační funkci lesů. V minulosti byl hlavní význam lesů spatřován v poskytování cenné obnovitelné suroviny, ale dnes jsou považovány za významnou součást krajiny (Führer, 2000).

Poškození lesních porostů a zhoršení jejich zdravotního stavu velmi výrazně ovlivňuje procesy v krajině, zejména změny v mikroklimatu, hydrologii a erozi půdy (Košulic, 2009). Z tohoto důvodu je důležité mapovat nejen výskyt a rozsah lesních porostů, ale také jejich zdravotní stav. Pro tento účel je vhodné využít interpretaci obrazových dat DPZ, díky kterým je možné sledovat změny zdravotního stavu lesa nebo například vyhodnocovat škody po lesních kalamitách. Družicová data jsou pro tuto potřebu velmi vhodná, jelikož zachycují rozsáhlá území v pravidelných časových intervalech a jsou k dispozici poměrně rychle od okamžiku jejich pořízení, což může být výhodou pro potřeby rychlého zjištění škod při náhlých kalamitních událostech v lesních porostech. Užitečnou vlastností družicových dat je také to, že jsou schopná zaznamenat elektromagnetické záření ve spektrech, která nejsou lidskému oku viditelná.

Na našem území je v poslední době podrobně sledován vývoj kalamitního stavu lesů v Národním parku Šumava. Hlavní příčinou poškození lesů v této oblasti je přemnožení lýkožrouta smrkového, který se zavrtaný pod kůrou stromů živí lýkem. Lýko však zajišťuje transport vody a živin ve stromě, tudíž díky jeho úbytku dochází k poškození stromu, který začne usychat a nakonec uhyne. Poškození smrkových lesů způsobuje změny v transpiraci a také zvýšený odtok vody z této oblasti (Skuhřavý, 2007). Správa Národního parku Šumava musí v rámci lesního managementu tyto problémy vhodným způsobem řešit. Za účelem zastavení dalšího šíření lýkožrouta smrkového bylo na některých místech centrální části Šumavy přistoupeno i k odlesnění, které však může vést ke změně klimatu, srážko-odtokových poměrů nebo erozi. Mapování zdravotního stavu lesa a rozsah odlesněných oblastí je velmi důležitým požadavkem pro plánování péče o lesní porosty (Kučera, 2009).

Zdravotní stav lesa je posuzován zejména na základě pozemního šetření, které je ovšem velmi časově náročné a data za větší území není možné získat k jednomu časovému okamžiku. Kromě pozemního šetření se při zjišťování zdravotního stavu lesa uplatňují také metody

dálkového průzkumu Země, jejichž výhodou je právě získání informací z rozsáhlého území k jednomu datu (Ministerstvo zemědělství, 2010). Zdravotní stav lesa je zkoumán metodami DPZ zhruba od 70. let, kdy se začalo provádět letecké snímkování lesních ploch. I v Česku se v této době používaly infračervené letecké snímky pro monitoring poškození lesa v Krušných horách (Hájek, Svoboda, 2007). V 80. letech se začaly uplatňovat také družicové snímky a na našem území se již od poloviny 80. let využívají k hodnocení zdravotního stavu lesů družicové snímky Landsat-TM (Ministerstvo zemědělství, 2010). Nevýhodou družicových dat Landsat může být ovšem jejich nízké prostorové rozlišení (30 m). S rozvojem a vyšší dostupností družicových dat s velmi vysokým prostorovým rozlišením (v řádech několika metrů) roste také jejich využití pro sledování zdravotního stavu lesních porostů (Hájek, Svoboda, 2007). U takovýchto dat však vzniká problém při použití pixelové klasifikace, u které se výrazně projevuje efekt “soli a pepře”. Jedná se o velké množství osamocených pixelů, které se po provedení klasifikace v obraze nacházejí. Pro klasifikaci VHR dat je vhodnější použít klasifikaci objektovou (Ouyang et al., 2011).

Kromě klasických optických metod DPZ lze pro hodnocení poškození lesních porostů využít také hyperspektrální data nebo data z leteckého laserového skenování. Vlastností lesa, která může rovněž vypovědět o jeho zdravotním stavu, může být i jeho výška nebo hustota. Tuto informaci z optických dat nezískáme, ale lze k tomuto účelu využít data leteckého laserového skenování. Tato data jsou na poli DPZ poměrně novou technologií. Jedná se o metodu sběru dat, která využívá aktivní laserový paprsek k vytváření mráčka bodů o přesných prostorových souřadnicích, a to na základě odrazů tohoto paprsku na výrazných překážkách (Dolanský, 2004).

Hlavní cíl této diplomové práce byl stanoven na základě literární rešerše, jejíž souhrn je uveden v následující kapitole. Ze zpracované relevantní literatury je patrné, že ve většině odborných studií jsou lesy na základě jejich zdravotního stavu zařazovány většinou pouze do dvou maximálně tří klasifikačních tříd. Právě v tomto bodě byl spatřován potenciál pro předloženou DP v podobě rozlišení vyššího počtu tříd. Hlavním cílem diplomové práce tedy bylo vytvoření metodického postupu vhodného pro hodnocení poškození lesních porostů ve vybrané oblasti Národního parku Šumava při kombinaci multispektrálních a lidarových dat. Hypotézou je, že na základě tohoto metodického postupu bude přesně rozlišen o něco vyšší počet klasifikačních tříd než pomocí tradičních postupů založených na jednom druhu dat. Kombinace multispektrálních a lidarových dat umožní detailnější a přesnější rozlišení lesních porostů, které čelily disturbančním vlivům a jsou v určitém stádiu rozpadu či obnovy. Lesní porosty budou klasifikovány na základě jejich zdravotního stavu do 4 možná i 5 kategorií. Vycházíme z předpokladu, že při použití multispektrálního družicového snímku doplněného o informaci o výšce vegetace z dalšího typu dat bude možné rozlišit rozpadová stadia lesních porostů s vyšší přesností. Dalším cílem práce tak bylo zvolit

metodický postup, kterak z dat leteckého laserového skenování získat doplňující informaci o výšce lesního porostu. Tato informace byla použita jako jeden z příznaků při klasifikaci.

Ke zpracování byl využit multispektrální a panchromatický snímek vysokého rozlišení pořízený družicí SPOT a také data leteckého laserového skenování, která mimo jiné poskytují informaci o výšce lesního porostu. Data LLS byla pořízena z grantu k projektu GAČR (P209/12/0997) s názvem “Vliv disturbancí horské krajiny na dynamiku fluvialních procesů“, který je společně řešen na katedře fyzické geologie a geoekologie a katedře aplikované geoinformatiky a kartografie PřF UK v Praze. Tento projekt zkoumá disturbance horské krajiny, zejména změny struktury, rozsahu a zdravotního stavu lesní vegetace v důsledku různých příčinných procesů. Použita byla metoda objektové klasifikace a klasifikační báze byla vytvořena s využitím programu eCognition, jehož nejnovější verze 8.8 je k dispozici od října roku 2012. Nová verze programu přináší rozšíření především v oblasti zpracování lidarových dat. Pro zpracování dat z leteckého laserového skenování byla využita nová nadstavba software Envi s označením E3De (nebo také Envi Lidar). Metodika zpracování dat vycházela z nejnovějších poznatků získaných z rešerše odborné literatury. Ve zpracované literatuře mnoho autorů upozorňuje na fakt, že kombinace lidarových a multispektrálních dat může přinést další potřebné informace pro hodnocení poškozeného lesního porostu.

Text práce je rozdělen do sedmi částí. Po stručném úvodu následuje teoretická část, ve které je nastíněna problematika zdravotního stavu lesů a jeho hodnocení pomocí metod DPZ. Dále tato část obsahuje stručný popis metod objektové klasifikace. Následuje popis zájmového území a v další části jsou představena použitá data a metodika. Hlavní část práce se věnuje popisu výsledků. V posledních dvou kapitolách jsou výsledky diskutovány a na závěr jsou shrnuty nejdůležitější poznatky.

## 2 LITERÁRNÍ REŠERŠE A ÚVOD DO PROBLEMATIKY

Dálkový průzkum Země je jedna z geoinformačních technologií, která umožňuje získávat informace o objektech na dálku bez přímého kontaktu s nimi (Dobrovolný, 1998). Možnosti a využití této technologie se rychle rozšiřují. Metody DPZ se uplatňují v mnoha oborech lidské činnosti, kde díky nim dochází k rychlému získání dat o velkém území a navíc umožňují ušetřit náklady a čas na rozsáhlé terénní šetření. Jedním z těchto oborů je i lesnictví, a to konkrétně monitorování stavu lesa a jeho disturbancí. Lesy tvoří významnou součást krajiny a jejich zdravotní stav je důležité sledovat zejména kvůli mapování škod případně plánování zásahů a lesního managementu. Vzhledem k tomu, že se dálkový průzkum v lesnictví uplatňuje již celou řadu let, existuje velké množství odborných článků zabývajících se využitím dat DPZ pro detekci lesa postiženého různými disturbancemi.

Disturbance je pojem, kterým se v krajinné ekologii označuje přechodná událost, která zabíjí, potlačuje nebo narušuje jednoho nebo více jedinců, čímž přímo či nepřímo otevírá prostor pro kolonizaci a rozvoj nových jedinců téhož či jiného druhu. Disturbance v podstatě modifikují a udržují přírodu. Podle původu lze rozlišovat disturbance způsobené antropogenními a přírodními faktory (Košulic, 2009).

Disturbance způsobené přírodními faktory nejsou zapříčiněny člověkem a lze je dále rozdělit na abiotické a biotické. Mezi abiotické disturbance patří požáry, laviny, povodně, extrémní sucha, vichřice nebo zemětřesení. Biotické disturbance jsou způsobeny například invazními druhy rostlin a živočichů, šířením nemocí a škůdců (Hesslerová, Kučera, 2006).

Disturbance, způsobené lidskou činností, jsou změnami náhlými a mohou mít za následek snižování popřípadě úplné vymizení druhů. Od přírodních disturbancí se antropogenní liší svým rozsahem, intenzitou a frekvencí. Mezi antropogenní disturbance řadíme procesy související s lidskou činností, jako odlesnění, zemědělství, rozvoj infrastruktury, těžba surovin nebo znečištění (Hesslerová, Kučera, 2006).

Lesní disturbance velmi výrazně ovlivňují procesy v krajině, zejména změny v mikroklimatu, hydrologii a erozi půdy. Vliv disturbancí na krajinu však může být negativní i pozitivní. Na určitém místě může být současný ekosystém vlivem intenzivní disturbance zničen, ale naopak mírná disturbance může přispět k utváření heterogenity krajiny (Košulic, 2009).

Šumavské lesy byly a stále jsou velmi sledovanou lokalitou na našem území, a to zejména z důvodu přemnožení lýkožrouta smrkového. Asi nejsledovanější byla oblast kolem Modravy a Březníku v roce 2011. Hlavním důvodem zvýšeného zájmu a rozruchu

panujícího kolem tohoto území jsou především rozepře o to, jakým způsobem má správa NP s napadenými a poškozenými lesy zacházet. Stojí zde proti sobě dva názory. Zastánci prvního tvrdí, že lesy by měly být ponechány samovolnému vývoji s tím, že se s přemnoženým hmyzem samy vypořádají. Příznivci druhého názoru jsou přesvědčeni, že by se šíření kůrovce mělo zastavit například vykácením napadených stromů.

Vzhledem k tomu, že k odtěžení části napadených stromů již došlo, je důležité sledovat rozsah tohoto zásahu a také je potřeba vhodným způsobem sledovat zdravotní stav lesních porostů v této oblasti. K tomuto účelu jsou vhodná právě data DPZ, jelikož zachycují rozsáhlé území a navíc jsou snímky pořizovány v pravidelných časových intervalech, což umožňuje sledovat nejen aktuální zdravotní stav lesa, ale i jeho změny v čase.

## 2.1 Využití DPZ při mapování lesa

Tradiční a nejstarší metodou zjišťování informací o lesních porostech je terénní průzkum. Ten je sice velmi přesný, ale na druhou stranu je časově a finančně velmi náročný. Nástup dálkového průzkumu Země přinesl revoluci v mapování lesa a výrazně zkrátil čas a náklady, potřebné pro pořízení dat (Kushwaha, 2012). Uplatnění metod DPZ v oblasti lesnictví má u nás i v zahraničí poměrně dlouhou tradici. Existuje celá řada odborných článků, která se zabývá využitím dat dálkového průzkumu v lesnictví. Z dat DPZ je možné zjišťovat různé charakteristiky lesa, jako například: klasifikace lesních porostů (jehličnatý, listnatý, smíšený), mapování zalesněné plochy a její změny v čase, odhad biomasy, mapování holých sečí, zjišťování škod po požárech nebo například identifikace poškozeného a suchého lesa (Hais, 2009).

První studie lesních porostů pomocí DPZ se zaměřovaly především na mapování zalesněné plochy a využívaly letecké snímky. Ty ovšem pokrývaly menší území a snímkování bylo prováděno nárazově nikoli pravidelně. Vypuštění první multispektrální družice Landsat (dříve ERTS) v roce 1972 odstartovalo novou éru v hodnocení lesních porostů i v DPZ obecně. Jednalo se o první satelit, který umožňoval systematické a opakované pozorování lesních porostů na rozsáhlém území. Tento satelit poskytoval kromě viditelného spektra také blízké a střední IČ pásmo a data jím poskytovaná usnadnila identifikaci lesních typů. Tato data jsou dodnes využívána. Postupně začala být dostupná data s vyšším prostorovým rozlišením. Významné bylo také vypuštění francouzské družice SPOT v roce 1986, která byla určena hlavně pro studium vegetace (Kushwaha, 2012). V průběhu času byl kladen důraz na vyšší prostorové, spektrální i časové rozlišení. V poslední době se do popředí dostávají data s velmi vysokým prostorovým rozlišením v řádu několika metrů až centimetrů, které umožňují identifikaci na úrovni jednotlivých stromů (Gisat, 200-?).

Kromě multispektrálních dat je možné pro hodnocení lesa použít také data hyperspektrální, radarová nebo data z leteckého laserového skenování (LLS, LiDAR). Právě zvyšující se dostupnost lidarových dat přináší nové možnosti pro hodnocení vlastností lesních porostů (Ke,

Quackenbush, Im, 2010). Tato data jsou na poli DPZ poměrně novou technologií. Jedná se o metodu sběru dat, která využívá aktivní laserový paprsek k vytváření mráčka bodů o přesných prostorových souřadnicích, a to na základě odrazů tohoto paprsku na výrazných překážkách (Dolanský, 2004). Lidarové technologie lze rozdělit do dvou základních kategorií: a) zaznamenávající jednotlivé odrazy, b) zaznamenávající celý průběh signálu pomocí křivky (*full-waveform*). Dále lze tato data dělit podle hustoty bodů na data s vyšší a nižší hustotou bodů (Hudak et al., 2002). Mnohé studie potvrdily, že lidarová data mají velký potenciál pro hodnocení lesní struktury. Jejich obecným využitím pro získání informací o lese se zabýval např. Wulder et al. (2012), Hyppä et al. (2001) nebo Zhao et al. (2011). Uvedení autoři potvrzují, že lidarová data poskytují cenné informace o lesní struktuře především ve vertikálním směru a využívají se zejména pro získání informací o výšce lesa, množství nadzemní biomasy nebo hustotě lesa. Yu et al. (2004) tento typ dat využil také pro detekci vykácených lesních oblastí a pro odhad lesního růstu.

Pro hodnocení lesních porostů jsou důležité informace jak z vertikálního, tak z horizontálního směru. V současné době ale neexistuje žádný senzor, který by dokázal získat informace z obou rovin najednou. K získání obou typů informací může však vést kombinace multispektrálních a lidarových dat (Hyde et al., 2006). Dá se říci, že tyto dva datové zdroje se navzájem doplňují. Lidar představuje jeden z nejlepších zdrojů informací pro odhad lesních strukturních parametrů a multispektrální data poskytují spektrální informace (Tonolli et al., 2011). Nejčastěji se tato kombinace dat využívá pro detekci budov, ale lze ji najít i v článcích zaměřených na lesní porosty. Kombinaci multispektrálních a lidarových dat využil například Hyde et al. (2006) pro stanovení výšky lesa a množství nadzemní biomasy, Tonolli et al. (2011) pro odhad objemu dřeva, Wulder et al. (2009) pro detekci lesů zasažených požárem nebo Ke, Quackenbush, Im (2010) a Dalponte, Bruzzone, Gianelle (2012) pro klasifikaci lesních dřevin. Všechny zmíněné články potvrzují zpřesnění výsledků oproti použití obou datových zdrojů samostatně.

## **2.2 DPZ a zdravotní stav lesních porostů**

Využití technik dálkového průzkumu Země v lesnictví již prokázala předchozí kapitola, ale velmi důležitou roli hraje DPZ zvláště při hodnocení zdravotního stavu lesní vegetace. Země s vysokou lesnatostí se nevyhnu problémům poškozených lesů. Ať už se jedná o disturbance přírodní nebo antropogenní, je potřeba tento jev sledovat. Na našem území (a nejen tam) je v současné době velmi aktuální napadení lesních porostů lýkožroutem smrkovým, a proto je následující kapitola zaměřena na odborné studie, které se zabývaly mapováním takového poškození s využitím dat DPZ. Lýkožrout může zasáhnout velmi rozsáhlé plochy a způsobit tak úmrtnost velkého množství stromů. Tvorba velkých oblastí

se suchým dřevem je dobrým základem například pro vznik požárů. Monitorování rozsahu postižených lesů je proto velmi důležité, a to jak pro odhad škod, tak pro plánování zásahů a lesního managementu.

Klasický způsob pro zjišťování zdravotního stavu lesa napadeného kůrovcem je pozemní šetření, které se využívá již dlouhou řadu let. V terénu se většinou vymezí sledované oblasti a v těch se vizuálně hodnotí odlistění a míra poškození stromů. Tato metoda sice poskytuje poměrně přesné výsledky, ale při rozsáhlých napadených plochách je velmi časově i finančně náročná. Nehledě na to, že některé oblasti mohou být špatně přístupné a informace nikdy nejsou získány k jednomu časovému okamžiku (Solberg et al., 2007). Data získaná metodou dálkového průzkumu Země se vztahují k jednomu časovému okamžiku a pokrývají oproti pozemnímu šetření velké územní celky. Navíc se snímkování provádí pravidelně a je tak umožněno sledovat nejen míru poškození k jednomu datu, ale i jeho vývoj v čase. Při napadení lesa kůrovcem dochází ke změně jeho spektrálních vlastností (viz. kapitola 2.3.1), a proto je možné techniky DPZ pro jeho hodnocení poměrně dobře využít (Wulder et al., 2006).

Existuje celá řada odborných článků zaměřených na hodnocení lesních porostů napadených kůrovcem pomocí dat DPZ. Tyto studie využívají různý typ dat i metodiku zpracování. Někteří autoři použili ke své práci letecké snímky (např. Hájek, Svoboda, 2007; Meddens, Jeffrey, Vierling, 2011) a jiní družicová data od nízkého prostorového rozlišení (např. Wang, 2009) až po prostorové rozlišení velmi vysoké (např. Denison, Brunelle, Solberg, 2010). Studie lze také rozdělit podle metodiky, která byla využita. Pro klasifikaci je využívána metoda pixelová (např. Meddens, Jeffrey, Vierling, 2011; White et al. 2005) i objektově orientovaná (např. Hájek, Svoboda, 2007). Některé studie využívají také vegetační indexy (např. Coops et al., 2006; Hais, 2009). K dispozici jsou i články, ve kterých lze nalézt jakýsi souhrn technik používaný pro hodnocení zdravotního stavu lesní vegetace (např. Wulder et al., 2006; Wang, 2009; Solberg et al., 2006).

Pro hodnocení zdravotního stavu kůrovcem napadeného lesa jsou často využívány letecké snímky. Tento druh dat ve své studii využili také Hájek a Svoboda (2007), kteří hodnotili odumírání horského smrkového lesa na Trojmezí (NP Šumava) metodou automatické klasifikace leteckých snímků. Pro práci využili časovou řadu barevných a IČ leteckých snímků s prostorovým rozlišením 0,42 m. Barevné snímky byly pořízeny ve třech spektrálních pásmech viditelné části spektra elektromagnetického záření a IČ snímky navíc obsahují IČ spektrální pásmo. Zpracování snímků zahrnovalo nejprve segmentaci obrazu a následně objektově orientovanou klasifikaci, která spočívala v tvorbě znalostní báze. Klasifikace proběhla do 4 tříd: (1) živý les, (2) suchý les, (3) holá půda a (4) stín. Přesnost klasifikace byla hodnocena pomocí Kappa koeficientu a jeho hodnota se pohybovala v rozmezí 0,85-0,93. Tato studie ukazuje, že je možné využít letecké snímky k tomuto účelu, ale tato data mají i své nevýhody. Mezi hlavní z nich patří časová a finanční náročnost jejich pořízení a menší rozměry nasnímané plochy. Snímkování se navíc neprovádí v pravidelných časových intervalech, ale pouze je-li to potřeba.



Infračervené letecké snímky pro svou práci použili také Meddens, Jeffrey a Vierling (2011), kteří se zaměřili na hodnocení potenciálu těchto dat pro mapování různých fází poškození lesa kůrovcem. Součástí jejich práce bylo také zhodnotit nejvhodnější prostorové rozlišení pro tento účel. Pro porovnání použili snímky s prostorovým rozlišením 30 cm, 1,2 m, 2,4 m a 4,2 m. Snímky byly klasifikovány do 4 kategorií: (1) nepoškozené a zelené stromy (2) poškozené stromy s červenými jehlicemi, (3) poškozené stromy bez jehlic a (4) nelesní oblasti. Pro klasifikaci použili metodu založenou na pixelovém přístupu s využitím klasifikátoru maximální pravděpodobnosti (*maximum likelihood*). Nejlepších výsledků bylo dosaženo při použití snímku s prostorovým rozlišením 2,4 m, kdy hodnota kappa koeficientu byla 0,88 a hodnota celkové přesnosti 90 %. U ostatních rozlišení se hodnota kappa koeficientu pohybovala v rozmezí 0,77-0,84, přičemž nejnižší přesnost byla zaznamenána u snímku s rozlišením 4,2 m. Z výsledků této práce vyplývá, že nejlepší prostorové rozlišení pro hodnocení lesních porostů je takové, které se blíží velikosti koruny stromu.

Jak již bylo, zmíněno letecké snímky mají své výhody, ale také nevýhody. Nevýhodu nepravidelného pořizování dat lze vyřešit použitím dat družicových. Ty navíc pokrývají mnohem větší území na jednom snímku a některé mají i vyšší spektrální rozlišení. Oproti leteckým snímkům mají družicová data nižší prostorové rozlišení, ale současné moderní senzory se mu velmi přibližují a velikost rozdílu je tak postupně zmenšována. Různým rozlišením družicových dat použitých pro hodnocení zdravotního stavu lesa se zabývá například Wang (2009). Volba vhodného prostorového rozlišení závisí na měřítku, ve kterém chceme mapování provádět. Pro mapování na globální úrovni postačí snímky s nízkým nebo středním prostorovým rozlišením, pro regionální úroveň můžeme použít prostorové rozlišení vysoké a pro lokální úroveň velmi vysoké. Detailnější informace o rozlišení družicových dat jsou uvedeny v kapitole 2.4. Použitelnost snímků s nízkým rozlišením prokázal Wang (2009), který ve své studii mapoval lesní disturbance pomocí družicových snímků MODIS s prostorovým rozlišením 1 km. Zájmovým územím v této práci byla celá jihovýchodní část USA.

Ve většině odborných článků, zabývajících se hodnocením kůrovcem napadeného lesa, jsou používány družicové snímky Landsat TM nebo ETM+. Tato data se svým prostorovým rozlišením 30 m u multispektrálního senzoru spadají do kategorie družicových dat s vysokým prostorovým rozlišením a jejich časové rozlišení je přibližně 16 dní. Důvodem jejich častého používání je například to, že jsou k dispozici zdarma a jejich archiv obsahuje obrovské množství snímků od roku 1972, ze kterých lze tvořit rozsáhlé časové řady až do současnosti (Gisat, 200-?). V České republice má hodnocení zdravotního stavu lesů ze snímků Landsat-TM již určitou tradici (přibližně od r. 1986). Podle některých autorů mají tato data ale i své nevýhody, jako je například jejich ne příliš vysoké prostorové rozlišení. Jako negativum se jeví také nižší časové rozlišení s ohledem na častý výskyt oblačnosti panující nad horskými oblastmi na našem území (Hájek, Svoboda, 2007).

Hais (2009) použil data Landsat TM 5 a ETM+ 7 pro sledování 2 typů lesních disturbance: rozpadlých horských smrčů vzniklých napadením lýkožrouta smrkového a holých sečí

vytvořených jako obrana proti jeho šíření. Autor použil transformaci Tasseled Cap, která redukuje všechna spektrální pásma snímku pouze na tři: jas (*brightness*), vlhkost (*wetness*) a zeleň (*greenness*). Předpokladem bylo, že v průběhu disturbance lesa budou hodnoty jasu stoupat a hodnoty zeleně a vlhkosti klesat. Z těchto složek byl následně vypočten index DI (*Disturbance index*), který autor ještě mírně upravil do podoby DI':

$$DI = \text{Brightness} - (\text{Greenness} + \text{Wetness})$$

$$DI' = \text{Brightness} - \text{Wetness}$$

Kromě tohoto indexu bylo k hodnocení disturbance použito také termální pásmo snímku. Hodnoty v termálním pásmu byly sledovány před disturbance a po ní. Výsledky ukázaly, že vykáčené oblasti se na snímku projeví větší změnou v hodnotách indexu než v případě suchých smrčín poškozených kůrovcem. Totéž ukázaly i výsledky zjištěné z termálních družicových dat. Vykáčené oblasti se mnohem více přehřívají než smrčiny napadené kůrovcem.

Družicové snímky Landsat, transformaci Tasseled Cap (TC) a výpočet indexu disturbance (DI) použil také White et al. (2005). Podle něj má transformace TC schopnost zdůraznit důležité změny v lesní vegetaci. Index DI poskytuje informace o tom, v jakém pixelu vykazuje lesní vegetace vysoké hodnoty zeleně a vlhkosti a v jakém naopak dominuje složka jasu. Dokáže tak oddělit plochy vykáčeného lesa od ploch zalesněných. Index poskytl poměrně dobré informace o místech, která byla velmi výrazně postižena disturbance. Jeho nevýhodou může být to, že nedokáže postihnout drobnější rozdíly ve zdravotním stavu vegetace. Transformaci TC pro hodnocení poškození lesa použil také Jin a Sader (2005). Jejich studie porovnává využití složky zeleň (*greenness*) z transformace a index NDMI (*Normalized Difference Moisture Index*):

$$NDMI = (NIR - SWIR) / (NIR + SWIR)$$

Podle autora NDMI koreluje s obsahem vody ve vegetaci mnohem lépe, než NDVI a na rozdíl od NDVI má schopnost odhalit lehčí poruchy ve zdravotním stavu a dosahuje vyšší přesnosti. Složka zeleně z TC i index NDMI podávají velmi podobné výsledky, které jsou použitelné pro detekci poškozeného lesa. Podobnou metodiku pro hodnocení poškozených a zdravých lesů použili také DeRose, Long a Ramsey (2011), kteří klasifikovali snímky Landsat z různých let na základě vypočteného indexu DI. Využili metodu pixelové klasifikace a dosáhli celkové přesnosti v rozmezí 80-82 %. Z Časové řady snímků Landsat byl následně vyhodnocen průběh poškození lesa ve sledovaném období. Meddens et al. (2013) rovněž využil časovou řadu snímků Landsat od roku 1996 do roku 2011, na základě kterých hodnotil vývoj poškození lesa kůrovcovou kalamitou v severním Coloradu a jižním Wyomingu. Snímky klasifikoval do 4 kategorií: (1) nepoškozené a zelené lesy, (2) poškozené lesy ve fázi red-attack, (3) travní porosty, (4) ostatní plochy. Ke klasifikaci použil pixelový přístup s klasifikátorem maximum likelihood, protože již byl úspěšně použit v jiných studiích.

Kromě dat Landsat se v odborných článcích objevila také jiná data s vysokým prostorovým rozlišením. Solberg et al. (2007) využil data SPOT pro odhad odlistění lesů napadených hmyzem v Norsku. Odlistění je reakce lesa na určitý stres a pro jeho hodnocení byl využit index LAI (*Leaf Area Index*). Ten byl vypočten z dat leteckého laserového skenování pomocí Beer-

Lambertova zákona. Při defoliaci dochází ke zvýšení odrazivosti v oblasti středního infračerveného pásma a červeného pásma. Ze snímku SPOT byly tedy vytvořeny jednoduché mapy defoliace pouze na základě změny odrazivosti ve středním infračerveném pásmu a také mapy NDVI. Studie ukázala, že defoliace způsobená hmyzem může být mapována několika způsoby. Využita mohou být data leteckého laserového skenování (LLS) i snímky SPOT, na kterých je možné defoliaci zjistit pouze na základě zvýšení odrazivosti v pásmu SWIR nebo na základě snížení hodnoty NDVI.

V poslední době se do popředí dostávají družicová data s velmi vysokým prostorovým rozlišením, která se díky tomu velmi blíží leteckým snímkům. Mnoho odborných studií zaměřených na hodnocení poškozených lesů napadených hmyzem tato data využívá. Mezi taková data patří např. snímky družice IKONOS, které úspěšně analyzoval White et al. (2005) za účelem detekce stromů napadených kůrovcem druhu *Dendroctonus ponderosa*. Multispektrální snímek pořízený touto družicí má prostorové rozlišení 4 m a panchromatický 1 m. Tato velikost pixelu má mnohem blíže k velikosti objektu zájmu (koruna stromu) na rozdíl od velikosti pixelu dat Landsat a dochází tak ke snížení účinku smíšených pixelů. Smíšené pixely znamenají, že při větším rozměru pixelu je jeho spektrální hodnota tvořena všemi objekty, které se na jeho území nacházejí. U snímků Landsat je velikost pixelu 30 x 30 m a na jeho území se tak může nacházet větší množství stromů v různé fázi napadení i travní porosty nebo dalšími objekty. U snímků s velmi vysokým rozlišením je velikost pixelu 5 x 5 m a menší, tudíž je množství stromů v pixelu nižší.

VHR multispektrální data QuickBird s prostorovým rozlišením 2,5 m pro detekci kůrovcem napadených lesů v Britské Kolumbii v Kanadě využil Coops et al. (2006). Snímek klasifikoval na základě indexu RGI, kterým úspěšně oddělil poškozené stromy od nepoškozených. Klasifikaci prováděl na úrovni jednotlivých korun stromů, které byly detekovány z panchromatického snímku s prostorovým rozlišením 0,68 m. Velmi podobnou metodiku na stejném území použil také Wulder et al. (2008), který provedl multitemporální analýzu dat QuickBird a zjišťoval vývoj poškození lesa kůrovcem v letech 2003-2006. Navíc použil segmentaci obrazu a v jednotlivých segmentech určoval poměr zelených a poškozených stromů. Hicke a Logan (2009) rovněž klasifikovali snímek QuickBird za účelem zmapovat lesy poškozené kůrovcem v centrálním Idahu v USA. Na rozdíl od většiny studií do klasifikace zahrnuli veškerou vegetaci a nevytvořili masku pouze lesních oblastí. Pomocí řízené pixelové klasifikace s využitím klasifikátoru maximální pravděpodobnosti rozdělili snímek do 3 kategorií: (1) zdravé zelené stromy, (2) poškozené stromy, (3) travní porosty. K odlišení zelených a poškozených stromů byl využit index RGI, což je jednoduchý poměr červeného a zeleného spektrálního pásma. Tento index ovšem nedokázal odlišit stromy od travních porostů. K tomuto účelu byla využita informace o

odrazivosti v zeleném pásmu jako další proměnná klasifikace. Při klasifikaci bylo dosaženo celkové přesnosti 86 % a hodnota kappa koeficientu byla 0,82. Studie uspokojivě oddělila červené stromy od zdravých stromů a od travních porostů.

Zaostřením multispektrálních dat panchromatickým snímkem lze dosáhnout ještě vyššího prostorového rozlišení (viz kapitola 2.4.2) a tuto techniku využili Dennison, Brunelle a Carter (2010), kteří detekovali lesy poškozené kůrovcem ve Wayomingu v USA. Využili k tomu multispektrální snímek GeoEye-1 s rozlišením po zaostření 0,5 m. Snímek byl použit pro klasifikaci zelené, červené a šedé fáze poškození lesních porostů. Pro klasifikaci byla využita pixelová řízená klasifikace využívající klasifikátor maximální pravděpodobnosti. Nelesní oblasti byly z klasifikace vypuštěny a zbytek snímku byl rozdělen do 4 kategorií: (1) zdravé zelené lesy, (2) poškozené lesy ve fázi „red-attack“, (3) poškozené lesy ve fázi „grey-attack“ a (4) stíny. Výsledky studie ukazují, že VHR data jsou slibným nástrojem pro mapování poškození lesních porostů v důsledku napadení hmyzím škůdcem.

Jak je patrné z výše zmíněných odborných článků, ke klasifikaci poškozených lesů napadených kůrovcem lze kromě spektrálních informací z původních pásem snímku použít také odvozené informace ve formě vegetačních indexů. Normalized Difference Vegetation Index (NDVI) je asi nejznámější a nejvíce používaný vegetační index. Jedná se o podíl rozdílu a součtu blízkého infračerveného pásma a červeného pásma. NDVI odděluje zelenou vegetaci od ostatního povrchu, protože chlorofyl v zelené vegetaci absorbuje červené záření a odráží blízké IČ záření. Hodnoty NDVI se nacházejí v intervalu od -1 do 1 a čím je hodnota vyšší, tím je také obsah vegetace větší. Mapy NDVI mohou být vhodným ukazatelem pro studium zdravotního stavu lesa (Wang, 2009).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Velmi často se v prostudovaných článcích objevoval také index RGI, který poměrně dobře odděluje zdravé zelené stromy od stromů poškozených. Jedná se o jednoduchý poměr červeného a zeleného pásma. Jeho aplikace spočívá ve zvýraznění barevné změny listů od zelené k červené, která značí nenávratné poškození stromu. Tento index ve své práci použil například Coops et al. (2006), Meddens, Jeffrey, Vierling (2011) nebo Hicke, Logan (2009).

K určení obsahu vody ve vegetaci se obvykle používají hodnoty odrazivosti z oblasti středního a blízkého IČ pásma. Index založený na poměru těchto dvou pásem se nazývá Normalized Difference Moisture Index (NDMI). Podle Jina a Sadara (2005) NDMI velmi dobře koreluje s obsahem vody ve vegetaci a na rozdíl od NDVI má schopnost odhalit menší rozdíly ve zdravotním stavu lesa. Tento index použil například Meddens et al. (2013) pro detekci kůrovcem poškozeného lesa z družicových snímků Landsat.

Jelikož lesy tvoří významnou součást krajiny, jejich poškození má významný vliv na procesy v ekosystému a proto je mapování poškozeného lesa velmi důležité (Hicke, Logan,


2009). Informace získané z družicových dat jsou dále podstatné nejen pro sledování šíření poškození lesů kůrovcem, ale také pro plánování zásahů v napadené oblasti (White et al., 2005). Existuje celá řada studií, které se zaměřují na mapování kůrovcem poškozených lesů. Většina z nich je však omezena pouze na jeden druh dat (buď letecká, nebo družicová). Zejména kombinace multispektrálních dat s daty leteckého laserového skenování představuje slibný nástroj pro hodnocení zdravotního stavu lesa (Solberg et al., 2006). Sledování zdravotního stavu lesní vegetace bude i v budoucnosti aktuální a potřebné například pro potřeby lesního managementu a právě kombinace těchto dvou typů dat je vhodným předmětem pro další studium a výzkum. Právě z toho důvodu jsem se v práci zaměřila na kombinaci těchto dat. Data LLS pro oblast Šumavy existují, byla ale pořízena primárně pro topografické účely, proto je jejich hustota poměrně malá. Sama o sobě se tedy nehodí pro podrobné analýzy struktury lesních porostů a bude proto studováno jejich využití v kombinaci s multispektrálními družicovými daty vysokého prostorového rozlišení.

## 2.3 Spektrální projev vegetace

Základním fyzikálním jevem, na kterém je dálkový průzkum založen, je interakce elektromagnetického záření se zkoumaným látkovým objektem. Elektromagnetické záření se šíří beze změn pouze v prostředí, které je dokonale homogenní. V opačném případě každá nehomogenita působí změnu v charakteristikách tohoto záření. Nehomogenitou je v reálném prostředí každý hmotný objekt na zemském povrchu nebo v atmosféře. Hlavním smyslem DPZ je stanovit určité fyzikální vlastnosti měřené látky nebo objektu z naměřených hodnot spektrální intenzity odraženého nebo emitovaného elektromagnetického záření. Využívá se při tom charakteristických spektrálních vlastností různých materiálů (Kolář, Halounová, Pavelka., 1997). Obecně lze říci, že každá látka na zemském povrchu se vyznačuje vlastní spektrální charakteristikou. Pro daný objekt lze sestavit závislost mezi jeho odrazivostí a vlnovou délkou. Průběh této závislosti bude pro tento objekt více méně typický. Tato charakteristika je označována jako spektrální křivka odrazivosti a je projevem tzv. spektrálního chování objektů. Tvar křivky má velký vliv na výběr vhodné vlnové délky, ve které budou data o objektu získávána (Dobrovolný, 1998).

Vegetace (travní porosty, lesy, parky atd.) představuje výraznou dominantu krajiny a je obsažena téměř na všech družicových nebo leteckých snímcích. Spektrální projev vegetace je výsledkem odrazivých a emisních vlastností různých částí rostliny, ale dominující jsou však příspěvky od listů. Spektrální křivka odrazivosti listu se dělí na tři části, a to na oblast pigmentační absorpce (0,4 – 0,7  $\mu\text{m}$ ), oblast buněčné struktury nebo také vysoké odrazivosti (0,7 – 1,3  $\mu\text{m}$ ) a oblast vodní absorpce (1,3 – 3,0  $\mu\text{m}$ ). Schematická křivka spektrálního chování vegetace v oblasti viditelného a IČ záření je znázorněna na následujícím obrázku (*obr. 1*).

Obr. 1: Křivka spektrálního chování vegetace: A – oblast pigmentační absorpce, B – oblast buněčné struktury, C – oblast vodní absorpce (zdroj: Dobrovolný, 1998)



Průběh spektrální křivky listu ve viditelné části spektra ovlivňují nejvíce pigmentační látky (především chlorofyl a karoteny). Nejrozšířenějším pigmentem u většiny rostlin je chlorofyl, který může tvořit až 65 % listového pigmentu. Ten pohlcuje většinu záření v modré (0,45 μm) a červené (0,65 μm) části spektra. Tyto dva absorpční pásy jsou charakteristické pro oblast pigmentační absorpce a mezi nimi se nachází lokální maximum odrazivosti v zelené (0,54 μm) části spektra, která je příčinou zelené barvy rostlin ve vegetačním období (Kolář, Halounová, Pavelka, 1997).

Pro vegetaci je typický výrazný nárůst odrazivosti ve vlnových délkách kolem 0,7 μm. Tuto skutečnost ovlivňuje hlavně morfologie listu, která se však u jednotlivých druhů rostlin mění. Materiály pořízené v oblasti buněčné struktury díky tomu poskytují největší možnost pro odlišení ploch pokrytých vegetací od ostatních ploch a také pro rozlišení jednotlivých druhů vegetace (Dobrovolný, 1998).

Spektrální odrazivost v oblasti vodní absorpce je formována třemi absorpčními pásy vody na vlnových délkách 1,4 μm, 1,9 μm a 2,7 μm. Lokální maxima odrazivosti se vyskytují na vlnových délkách 1,6 μm a 2,2 μm. V této části spektra je odrazivost přibližně nepřímo úměrná obsahu vody v listu (Kolář, Halounová, Pavelka, 1997).

Odráživost vegetace však není formována pouze listy, ale i dalšími částmi rostlin (kmeny stromů, větve, květy, plody atd.). Odráživost celkového vegetačního krytu je proto nižší než hodnoty odrazivosti pro „průměrný“ list. Na základě výše uvedených informací lze z družicových snímků například odlišovat listnatý a jehličnatý les. Listnaté i jehličnaté lesy mají velmi podobné spektrální chování ve viditelné části spektra, ale v oblasti IČ vlnových délek jsou jehličnaté lesy charakterizovány nižšími hodnotami odrazivosti než lesy listnaté. Na spektrální chování vegetace má také velký vliv její zdravotní stav. U poškozené vegetace klesá aktivita chlorofylu a dochází ke zvýšení odrazivosti v červené a modré části spektra a výrazný pokles odrazivosti v IČ části spektra. Díky zvýšené odrazivosti v červené části spektra dochází ke žloutnutí rostlin a tohoto jevu lze poměrně dobře využít při mapování zdravotního stavu vegetace (Dobrovolný, 1998).

### 2.3.1 Spektrální projev lesa napadeného kůrovcem

Vegetace, do níž patří i lesy, má charakteristický spektrální projev. Ten je ovšem ovlivňován mnoha faktory a jedním z nich je aktuální zdravotní stav. Zdravotní stav lesů v NP Šumava je ovlivněn zejména napadením stromů lýkožroutem smrkovým, který patří do řádu brouků čeledi kůrovcovitých. Průběh tohoto napadení probíhá v několika fázích a každá z nich má své spektrální charakteristiky. K napadení stromů dochází většinou v pozdním létě. Po napadení kůrovcem zůstává jehličí stromů několik měsíců stále zelené, a tato fáze se označuje jako „zelená fáze“ (green-attack). Lesy nacházející se v této fázi není možné z družicových nebo leteckých snímků identifikovat, protože se vizuálně nijak neliší od zdravých a nenapadených lesů. Na jaře nebo počátkem léta následujícího roku začíná jehličí napadených stromů měnit barvu. Zelené jehličí postupně zesvětluje, až později zcela zrezne, což je způsobeno vysušováním a ztrátou chlorofylu. Přibližně rok po útoku jsou již na stromě všechny jehlice červené, a proto je tato fáze označována jako „červená“ (red-attack). Les nacházející se v tomto stádiu se na snímcích projevuje poklesem odrazivosti v zelené části spektra a naopak zvýšením odrazivosti v červené části spektra. Po 3 až 5 letech po napadení začnou jehlice stromů opadávat, až zůstanou jen holé a suché větve a les se dostane do „šedé“ fáze (grey-attack). Z důvodu ztráty jehličí se spektrální vlastnosti takového lesa blíží již k vlastnostem holé půdy spíše než k vegetaci. Kromě změny barvy nebo opadu jehličí dochází u poškozených stromů také ke ztrátě kůry (Wulder et al., 2006; Zahradník, Knížek, 2007). Ukázka kůrovcem napadeného lesa v různé fázi poškození je na následujícím obrázku (obr. 2).

*Obr. 2: Les napadený kůrovcem v červené fázi (vlevo) a v šedé fázi (vpravo)  
(zdroj: Zahradník, Knížek, 2007)*



## 2.4 Data laserového skenování

Lidar je zkratka odvozená z anglických slov *Light Detection and Ranging* a jedná se o laserový skener. Tento přístroj obsahuje zdroj laserového záření, optickou soustavu, mechanický prvek, detektor elektromagnetického záření a velmi přesné hodiny. Laserový skener lze zařadit mezi aktivní senzory neboť vysílá energii a přijímá zpět signál po odrazu. Měření pomocí tohoto skeneru není závislé na slunečním světle a lze jej provádět 24 hodin denně (Dolanský, 2004). Laserové skenování patří k nejmodernějším metodám sběru prostorových dat a skener funguje na poměrně jednoduchém principu. Zdroj záření v přístroji vytváří laserový paprsek (obvykle v infračervené části spektra), který je optickou soustavou rozmetán do zorného pole skeneru. Tyto paprsky se odrážejí od objektů a vrací se zpět ke skeneru, který zaznamenává souřadnice nejméně jednoho prostorového bodu. Na jeden vyslaný impuls lze získat až několik odrazů. Impulsy jsou vysílány opakovaně, pokaždé jiným směrem. Výstupem laserového skenování je soubor 3D souřadnic odražených bodů tzv. *mračno bodů* (Geodis, 200-?).

Podle umístění laserového zařízení se rozlišuje pozemní, letecké a mobilní laserové skenování. Při pozemním LS je přístroj umístěn staticky na zemi, při leteckém LS v letadle či vrtulníku a při mobilním LS na speciálně upraveném vozidle (Geodis, 200-?). Dále lze laserové skenery dělit podle způsobu zaznamenávání odrazů na přístroje zaznamenávající pouze několik odrazů (*discrete return*) a ty, které zaznamenávají velké množství odrazů (*full waveform*). Dále je možné dělení podle hustoty výsledného bodového mračna (Potůčková, 2012).

Primární použití technologie leteckého laserového skenování je pro tvorbu digitálního modelu terénu a povrchu, ale lze ji použít také například pro tvorbu 3D modelů měst, mapování průběhu elektrického vedení nebo pro mapování vegetace (Dolanský, 2004). V několika odborných studiích byla tato data použita pro zjišťování strukturních vlastností lesa (př. Solberg et al., 2006; Zhao et al., 2011). Pokud však jsou k tomuto účelu použita pouze data LLS je zapotřebí mít k dispozici taková, která mají vysokou hustotou zaznamenaných bodů. Jejich pořizovací cena je však poměrně vysoká, a proto je vhodné použít data LLS s nižší hustotou a zkombinovat je například s daty multispektrálními. Kombinace těchto dvou typů dat se využívá zejména při studiích v zastavěných oblastech (např. při extrakci budov nebo silnic), ale při studiích týkajících se lesních porostů není tato kombinace v odborné literatuře příliš častá.

## 2.5 Družicová data

Družicová data představují hlavní zdroj informací pro hodnocení zdravotního stavu lesní vegetace metodami DPZ. Předností družicových snímků je zejména schopnost zmapovat rozsáhlé oblasti během okamžiku a jsou uživateli k dispozici do několika dní či dokonce hodin po nasnímání. V porovnání s terénním šetřením, které se pro zjišťování zdravotního stavu lesa



často používá, přinášejí družicové snímky aktuální informace o rozsáhlém území k jednomu okamžiku a za nižších časových i finančních nákladů. Místa, která mohou být terénním šetřením obtížně dostupná, nebo jsou postižena přírodní katastrofou, umožňují družicová data zmapovat bezkontaktně, což je jejich další výhoda. Při porovnání s leteckými snímky mají družicové větší počet spektrálních pásem (Arcdata Praha, 2012).

V současné době pořizuje obrazová data pro komerční účely několik desítek družic. Tato data mají různé vlastnosti a nejčastěji se dělí podle rozlišovací schopnosti. Podle Dobrovolného (1998) lze definovat čtyři základní typy rozlišovací schopnosti: radiometrickou, spektrální, prostorovou a časovou. *Radiometrická rozlišovací schopnost* je dána citlivostí detektoru na sílu signálu, který je zaznamenáván. Definuje počet rozlišitelných úrovní signálu a udává se v mocninách dvou. Nejčastěji jsou snímky 11-bitové, to znamená, že jednotlivé pixely nabývají hodnot 0-2047 ( $2^{11}$ ). Starší data jsou 8-bitová a pixely tak nabývají hodnot 0-255 ( $2^8$ ) (Arcdata Praha, 2012). *Spektrální rozlišovací schopnost* udává šířku intervalu (pásma, kanálu) vlnových délek, ve kterém senzor zaznamenává elektromagnetické záření. Šířka kanálu může být velká, jako je tomu v případě pásma panchromatického, které zaznamenává celé viditelné spektrum, nebo naopak velmi úzká. Spektrální rozlišovací schopnost je také definována jako počet pásem, ve kterých je obrazový záznam vytvářen (Dobrovolný, 1998). *Prostorová rozlišovací schopnost* určuje, jak velké území na zemském povrchu odpovídá jednomu pixelu na snímku. Určuje tak velikost objektu, který může být na snímku ještě rozpoznán. Obecně malý pixel udává velké prostorové rozlišení a velký pixel rozlišení malé. *Časová rozlišovací schopnost* udává návratnost družice nad stejné místo na Zemi. Toto rozlišení je důležité v případě, že chceme získat časovou řadu snímků zájmového území. Většina družic snímá stejné místo přibližně každé tři dny. Výjimkou je např. družice Formosat-2, která díky své jedinečné dráze umožňuje snímat stejné místo každý den ve stejnou hodinu a pod stejným úlem (Arcdata Praha, 2012).

### 2.5.1 Družicová data podle prostorového rozlišení

V posledních letech nastal obrovský posun zejména v oblasti prostorového rozlišení družicových dat. V současnosti jsou k dispozici družicové snímky s takovým prostorovým rozlišením, které se pomalu blíží rozlišení snímků leteckých. I při tomto detailu mají družicové snímky vysoké spektrální rozlišení. Podle webových stránek firmy Gisat lze družicová data rozdělit podle prostorového rozlišení do tří kategorií: (1) data s nízkým a středním rozlišením, (2) data s vysokým rozlišením a (3) data s velmi vysokým rozlišením.

Družicová data s nízkým rozlišením jsou často označována zkratkou LR (z anglického *Low Resolution*) a jejich prostorové rozlišení se pohybuje v řádu 1 km. U dat se středním prostorovým rozlišením (MR, *Medium Resolution*) se hodnota tohoto rozlišení pohybuje v řádu 100 m. Tento typ dat se vyznačuje velkou šířkou záběru a jsou pořizována zpravidla v denním až několikadenním intervalu. Tato data jsou vhodná zejména pro mapování v globálním nebo

kontinentálním měřítku. Mezi družice pořizující data s tímto rozlišením patří například družice Terra se senzorem MODIS (1 km), SPOT 5 se senzorem VEGETATION 2 (1 km), Envisat vybavený senzorem MERIS (300 m) nebo Landsat 8 se senzorem TIRS (100 m) (Gisat, 200-?). Použitelnost snímků s nízkým rozlišením prokázal Wang (2009), který ve své studii mapoval lesní disturbance pomocí družicových snímků MODIS s prostorovým rozlišením 1 km.

Snímky s vysokým rozlišením jsou označovány zkratkou HR (*High Resolution*) a jejich prostorové rozlišení se pohybuje v řádu 10 m. Družice pořizují data v pravidelném několikátýdenním intervalu a modernější z nich umožňují pořízení dat i na základě konkrétní žádosti zákazníka. Tato data jsou vhodná pro mapování především na regionální úrovni a jsou pro hodnocení zdravotního stavu velmi často používána. Nejznámější a nejvyužívanější družicí v této kategorii je družice Landsat 5-TM a Landsat 7-ETM+ s prostorovým rozlišením 30 m. Tato data jsou využívána ve většině odborných článků, zabývajících se hodnocením kůrovcem napadeného lesa (např. Hais, 2009; Meddens et al., 2013 nebo Healey et al., 2005). Kromě snímků Landsat lze z této kategorie jmenovat také družice SPOT 4 (20 m) nebo SPOT 5 (10 m), které využil například Solberg et al. (2007) pro odhad odlistění lesů napadených hmyzem v Norsku.

V poslední době se do popředí dostávají zejména družicová data s velmi vysokým prostorovým rozlišením (VHR, *Very High Resolution*) vzhledem k jejich snazší dostupnosti a detailním informacím, které poskytují. Tato data patří v současnosti k nejrychleji se rozvíjícímu sektoru DPZ a většina těchto družic umožňuje pořízení dat podle konkrétních požadavků zákazníka. Jejich prostorové rozlišení se pohybuje v řádu 1 m a jsou vhodná pro podrobné mapování na lokální úrovni. Do této kategorie spadají například družice Ikonos (4 m), QuickBird (2,4 m), GeoEye-1 (2 m) nebo WorldView-2 (1,84 m). VHR data ve svých studiích hodnotících kůrovcem napadené lesy využil např. White et al. (2005), Coops et al. (2006) nebo Denison, Brunelle, Carter (2010). Podle Meddence, Jeffreyho a Vierlinga (2011) jsou tato data nejvhodnější pro hodnocení lesních porostů z toho důvodu, že se jejich rozlišení blíží velikosti koruně stromu.

Uvedené prostorové rozlišení se týká družicových snímků pořízených v multispektrálním režimu. Některé družice pořizují data zároveň také v panchromatickém režimu. Tato data mají většinou prostorové rozlišení několikrát vyšší než multispektrální a díky tomu je možné provést tzv. zaostření multispektrálního obrazu panchromatickým (pansharpening) o kterém detailněji pojednává následující kapitola 2.5.2.

## 2.5.2 Pansharpening

Družicová data, která jsou na trhu, se liší svým spektrálním, časovým a především prostorovým rozlišením. V současné době se kladou čím dál větší nároky zejména na geometrickou přesnost těchto dat reprezentovanou velikostí pixelu. S potřebou zvýšení geometrického rozlišení se

začaly rozvíjet metody pansharpeningu. Většina družic pořizuje data současně ve dvou režimech, panchromatickém a multispektrálním. Prostorové rozlišení panchromatických dat je přitom zpravidla 4x vyšší než u dat multispektrálních. Použití metody pansharpeningu umožňuje spojení obou typů dat vedoucí k získání barevného produktu s maximální podrobností (Šadibol, Chudý, 2013).

Pansharpening (*Image Fusion*) je technika digitálního spojení obrazových dat, která kombinuje panchromatická a multispektrální data. Výsledným produktem je zaostřený multispektrální snímek s velikostí pixelu, která odpovídá velikosti v panchromatickém snímku. Lze tedy říci, že je díky této metodě získán snímek s vysokým prostorovým i spektrálním rozlišením (Vijayaraj, 2004).

Existují různé pansharpening algoritmy např. Broveyova transformace, IHS, PCA, statistická metoda, metoda založená na vlnové délce a další (Vijayaraj, 2004). Nevýhodou většiny klasických algoritmů používaných v minulosti (př. IHS) bylo barevné zkreslení ve výsledném obraze. Omezující byl i limit pouze tří vstupních pásem z multispektrálního obrazu. Nejnovější algoritmy, které jsou dnes používány, tyto problémy již překonaly a nejsou závislé na počtu vstupních pásem a také radiometrická přesnost původních dat je maximálně zachována. Příkladem software, který využívá nejnovější algoritmus je například PCI Geomatica (Šadibol, Chudý, 2013).

V programu PCI Geomatica je pro pansharpening implementován postup, který má patentován Dr. Yun Zhang z University of New Brunswick. V programu jej nalezneme v knihovně algoritmů pod označením PANSHARP. Tento algoritmus byl v několika nezávislých odborných testech ohodnocen jako nejlepší a je pro tento typ zpracování všeobecně doporučován (PCI Geomatics, 2001). Uvedený algoritmus byl použit i v této práci pro zaostření multispektrálního snímku SPOT snímkem panchromatickým.

## 2.6 Objektová klasifikace

Klasifikace obrazu je proces, při kterém jsou jednotlivé obrazové prvky (pixely) zařazovány do předem definovaných klasifikačních tříd. Cílem je nahradit původní hodnoty radiometrických veličin hodnotami, které vyjadřují, jakou třídu pixel reprezentuje. Volba klasifikačních tříd závisí na účelu projektu a obrazové prvky jsou do těchto tříd zařazovány pomocí klasifikátorů (Dobrovolný, 1998). Klasifikace obrazových dat DPZ představuje řadu metod a přístupů digitálního vyhodnocení snímků. Z hlediska způsobu a klasifikace rozlišujeme dva základní typy, a to pixelovou klasifikaci (per-pixel) a objektově orientovanou klasifikaci (OBIA). Pixelová klasifikace je historicky starší metodou a využívá pouze spektrální příznaky. Analýza obrazu je ovšem úspěšnější tehdy, jsou-li využívány i jiné příznaky než pouze spektrální, což modernější a novější metoda objektově orientované klasifikace umožňuje (Potůčková, 2012).

Objektově orientovaná analýza obrazu byla vyvinuta s cílem napodobit vizuální interpretaci snímků člověkem. Člověk při pohledu na družicový snímek nevnímá jednotlivé pixely, ale celé jejich shluky a podle barevných, tvarových, velikostních, kontextuálních, texturálních a dalších informací rozpoznává jednotlivé objekty. Prvním krokem objektové klasifikace je tedy rozdělení snímku na tyto objekty (tzv. segmentace) a následně aplikace klasifikačního modelu (Gisat, 200-?).

### 2.6.1 Porovnání s pixelovou klasifikací

Hlavní rozdíl mezi pixelovou a objektovou klasifikací je v základní jednotce, se kterou tyto metody pracují. V případě pixelové klasifikace je základní jednotkou zařazovanou do klasifikačních tříd samotný obrazový prvek (pixel) a tato metoda klasifikace využívá pouze spektrální vlastnosti těchto pixelů. Základní jednotkou u objektové klasifikace není jeden pixel, ale skupina prostorově souvisejících pixelů (objekt, segment). Tyto skupiny pixelů jsou vytvořeny procesem segmentace, jejímž cílem je vytvořit objekty, které se co možná nejvíce podobají objektům reálného světa. Při objektové klasifikaci nejsou uvažovány jen vlastnosti spektrální, ale například i textura, kontext, tvar nebo velikost objektů (Potůčková, 2012).

Existuje celá řada studií, které se zabývají porovnáním pixelové a objektové klasifikace. Například Myint et al. (2011) provedl toto porovnání při klasifikaci městské zástavby a zjistil, že výsledky pixelové klasifikace mají mnohem nižší přesnost než výsledky klasifikace objektové. Důvodem je právě zahrnutí dalších informací nikoli pouze spektrálních, jako je tomu u klasifikace pixelové. Podle Ouyanga et al. (2011) je výhodné použít objektovou klasifikaci zejména při práci s VHR daty. Touto metodou je eliminován zejména efekt osamocených pixelů (*salt and pepper effect*), ke kterému dochází při pixelové klasifikaci. Vzhledem k tomu, že objektová klasifikace pracuje s celými objekty nikoli s pixely, jsou navíc její výsledky pro člověka přirozenější.

Metoda objektové klasifikace se v dostupné literatuře využívá nejvíce pro detekci budov a klasifikaci zastavěných území (např. Halounová, 2002; Liu, Wang, Liu, 2005), ale i při klasifikaci zdravotního stavu lesa má tato metoda uplatnění. Například Hájek a Svoboda (2007) použili objektovou klasifikaci pro vyhodnocování odumírání horského smrkového lesa na Trojmezí v NP Šumava. Důvodem bylo použití vysoce texturovaných leteckých snímků, u kterých je, podle autorů, použití pixelové klasifikace nevhodné. Metodu objektové klasifikace použil také Morales, Miura, Idol (2008), kteří se ve své studii zabývali hodnocením suchého lesa s využitím snímků s velmi vysokým prostorovým rozlišením. Podle něj je objektová klasifikace pro tento účel vhodná zejména proto, že umožňuje zohlednit kromě spektrálních vlastností také další důležité charakteristiky zdravotního stavu, kterými jsou zejména vegetační indexy.


## 2.6.2 Segmentace

První fází objektové klasifikace obrazu, je segmentace. Pod tímto pojmem se rozumí dělení obrazových dat do oddělených regionů (shluků pixelů, segmentů) o definované míře homogenity a určité velikosti. Cílem segmentace je získat objekty, které se vzájemně nepřekrývají a mají pokud možno významovou souvislost s objekty reálného světa. Segmentace je důležitým krokem a její kvalita přímo ovlivňuje kvalitu výsledné klasifikace (Meinel, Neubert, 2004).

Existují dva základní principy segmentace, a to top-down a bottom-up. Segmentace založená na principu top-down postupuje od větších objektů k menším. Na začátku je celý obraz považován za jeden velký segment a ten je poté dále dělen na segmenty menší. Oproti tomu princip bottom-up postupuje od nejmenších objektů k větším. Na začátku procesu jsou za segmenty považovány jednotlivé pixely obrazu, které jsou postupně spojovány v segmenty větší. Program eCognition nabízí několik typů segmentačních algoritmů, jejichž výčet a detailní popis je uveden v dokumentaci, která je součástí programu. V této kapitole se zaměřím na popis pouze některých metod a metody, která byla při zpracování dat v této práci použita.

Nejjednodušší metoda, která je v programu k dispozici, je Chessboard segmentation. Ta rozděluje obraz na pravidelnou síť čtverců se stejnou velikostí (*obr. 3*). Tato metoda se využívá například u již identifikovaných malých objektů pro jejich další detailnější segmentaci.


*Obr. 3: Ukázka původního (vlevo) a segmentovaného obrazu metodou Chessboard Segmentation (vpravo)*



Podobnou metodou je Quadtree-Based Segmentation, která rovněž dělí obraz na čtvercové segmenty ovšem s různou velikostí (*obr. 4*). Nejprve je obraz rozdělen na pravidelnou čtvercovou síť. Ty čtverce, které nesplňují kritérium homogenity, jsou dále rozděleny na další 4 čtverce. Například pokud maximální barevný rozdíl uvnitř čtverce je větší než definovaná


prahová hodnota. Tento postup se opakuje, dokud není splněno kritérium homogenity u všech čtverců (Trimble, 2012).

*Obr. 4: Ukázka původního (vlevo) a segmentovaného obrazu metodou Quadtree-Based Segmentation (vpravo)*



Pro zpracování obrazových dat v této práci byla použita metoda Multiresolution segmentation, která podle Meinela a Neuberta (2002) podává nejlepší výsledky. Tento segmentační algoritmus přináší možnost vytvářet objekty v hierarchických úrovních. Každá vyšší úroveň je vytvořena sloučením objektů z úrovně nižší (Lizarazo, Elsner, 2002). Jedná se o segmentační metodu typu bottom-up, tím pádem jsou na jejím počátku za objekty považovány samostatné pixely. Tyto malé objekty jsou postupně sdružovány do větších. Ke sloučení dojde tehdy, je-li nárůst heterogenity (spektrální nebo tvarové) minimální. Pokud dojde k překročení definovaného prahu heterogenity algoritmus je ukončen (Trimble, 2012; Baatz, Schäpe, 2000). Výsledkem by měla být síť homogenních objektů, která se pokud možno co nejvíce blíží realitě (obr. 5).

*Obr. 5: Ukázka původního (vlevo) a segmentovaného obrazu metodou Multiresolution Segmentation (vpravo)*





Podle Hoffmana, Strobla a Blaschkeho (2008) se výpočet spektrální heterogenity, tvarové heterogenity a celkového kritéria sloučení objektů u multiměřítkové segmentace provádí pomocí následujících vzorců:

**Spektrální heterogenita**  $h_{color}$  je dána vztahem:

$$h_{color} = \sum_{k=1}^n w_k \cdot \sigma_k$$

$\sigma_k$  – směrodatná odchylka hodnot pásma  $k$   
 $w_k$  – váha pro pásmo  $k$   
 $n$  – počet segmentovaných pásem

**Tvarová heterogenita**  $h_{shape}$  je složena ze dvou dílčích kritérií, a to kritéria kompaktnosti  $h_{comp}$  a hladkosti  $h_{smooth}$ :

$$h_{shape} = w_{comp} \cdot h_{comp} + (1 - w_{comp}) \cdot h_{smooth}$$

$w_{comp}$  - váha pro kritérium kompaktnosti, uživatelem definovaná v rozmezí od 0 do 1

Kritéria kompaktnosti  $h_{comp}$  a hladkosti  $h_{smooth}$  jsou dána následujícími vztahy:

$$h_{comp} = \frac{l}{\sqrt{n}}$$

$l$  – obvodová délka hraniční linie segmentu  
 $n$  – velikost segmentu měřená v pixelech

$$h_{smooth} = \frac{l}{b}$$

$b$  – nejkratší délka obvodu čtyřúhelníku, opsaného obrazovému segmentu

**Celkové kritérium sloučení objektů**  $f$  je dáno vztahem:

$$f = w_{color} \cdot h_{color} + (1 - w_{color}) \cdot h_{shape}$$

$w_{color}$  – váha pro spektrální kritérium, uživatelem definovaná v rozmezí od 0 do 1

Ke spojení do větších segmentů dojde tehdy, pokud odmocnina z celkového kritéria sloučení objektů  $f$  je u již spojeného budoucího objektu nižší než měřítkový parametr (*scale*).

$$scale \geq \sqrt{f}$$

Jak plyne z výše uvedených vzorců, při provádění multiměřítkové segmentace je v programu eCognition uživatel vyzván k zadání vstupních parametrů. Prvním z nich jsou váhy jednotlivých spektrálních pásem (*Image Layer Weights*), kterými lze některou vrstvu označit za důležitější a naopak. Druhým volitelným parametrem je měřítkový parametr (*Scale Parametr*), který ovlivňuje velikost výsledných objektů. Čím větší je jeho hodnota, tím větší jsou vytvořené segmenty. Dalším parametrem je váha tvarového kritéria (*Shape*). Zadává se pouze váha tvaru z toho důvodu, že váha pro spektrální kritérium je automaticky uvažována jako doplněk do jedné. Maximální možná váha pro tvarové kritérium je 0.9, protože nelze spektrální kritérium vyloučit zcela. Posledním volitelným parametrem je váha pro kritérium kompaktnosti (*Compactness*). Opět je zadávána pouze váha pro kompaktnost a váha pro hladkost je dopočtena

jako doplněk do jedné (Trimble, 2012). Hodnota těchto parametrů není pevně stanovena a záleží čistě na uživateli, jaká kombinace se mu bude zdát jako nejvhodnější. Segmentace stejného snímku by u různých uživatelů mohla mít různé výsledky. Jedná se tedy o velmi subjektivní proces, kterému je dobré věnovat pozornost.

### 2.6.3 Klasifikace

Objektová klasifikace probíhá v podstatě ve dvou krocích. Prvním z nich je segmentace a po ní následuje samotná klasifikace obrazu. Klasifikace již neprobíhá na úrovni jednotlivých pixelů, ale na úrovni objektů vytvořených pomocí segmentace. Do předem definovaných klasifikačních tříd jsou tedy zařazovány celé segmenty (shluky pixelů) nikoli pixely jednotlivé (Gisat, 200-?). Tyto třídy, do kterých bude obraz klasifikován, je nutné před samotnou klasifikací definovat. K tomuto účelu slouží v programu eCognition panel hierarchie tříd (*Class Hierarchy*), který umožňuje vytváření nových tříd, přiřazování barev nebo definování parametrů, na základě kterých se budou objekty klasifikovat (Komrska, 2006).

Samotná klasifikace může být založena na tzv. tvrdých nebo měkkých klasifikátorech. Tvrdé klasifikátory (např. maximum likelihood, prahování) určují příslušnost daného objektu do třídy buď jako hodnotu 0 (nepřísluší) nebo jako hodnotu 1 (přísluší). Oproti tomu měkké klasifikátory (např. fuzzy systémy, Bayesovský klasifikátor) určují pravděpodobnost, s jakou objekt patří do všech klasifikačních tříd, v podobě hodnoty z rozmezí 0 až 1 (Potůčková, 2012).

Klasifikace v software eCognition je založena na fuzzy logice. Fuzzy model využívá tzv. funkce příslušnosti (*membership function*), logické operátory (and, or, not) a pravidla „jestliže-pak“. Funkce příslušnosti graficky reprezentuje míru náleženosti objektů do jednotlivých klasifikačních tříd. Tvar a meze této funkce se vytváří buď ručně, nebo automaticky na základě výběru vzorků. Popis jednotlivých tříd je tedy realizován pomocí tzv. klasifikačních fuzzy pravidel a souhrn všech použitých pravidel se označuje jako klasifikační báze (Gisat, 200-?). Fuzzy pravidla mohou být generována automaticky nebo vytvářena manuálně. Automaticky se fuzzy pravidla vytvářejí při použití klasifikátoru nejbližšího souseda (*Nearest Neighbour*), při kterém dochází ke sběru trénovacích ploch. Následně uživatel vybere příznaky, ze kterých je vytvořen příznakový prostor, a jsou vypočteny funkce příslušnosti. Klasifikátor nejbližšího souseda však uživatel nemusí použít a fuzzy pravidla si může vytvořit sám. V software eCognition lze využít také klasické prahování, které představuje nejjednodušší a nejrychlejší přístup, který se používá především na odvozené příznaky (Trimble, 2012).

Pokud to tedy shrneme, tak je možné v software eCognition klasifikovat třemi způsoby. Prvním z nich je řízená klasifikace s použitím klasifikátoru nejbližšího souseda, která fuzzy pravidla generuje automaticky. Druhým způsobem je klasifikace na základě uživatelem definovaných klasifikačních fuzzy pravidel. Třetí způsob představuje kombinace klasifikátoru nejbližšího souseda a uživatelky definovaných pravidel (Trimble, 2012).



Pro vytváření klasifikačních pravidel lze využít velké množství charakteristik objektů, které software eCognition nabízí. Charakteristiky se týkají celého posuzovaného objektu a patří mezi ně například spektrální charakteristiky, tvarové charakteristiky, texturální charakteristiky a další. Kromě objektových charakteristik, které již software obsahuje lze vytvářet také vlastní uživatelem definované charakteristiky. Této možnosti je využíváno většinou pro výpočet různých indexů, které se získají jednoduchou aritmetickou operací mezi již existujícími spektrálními pásmy (Trimble, 2012).

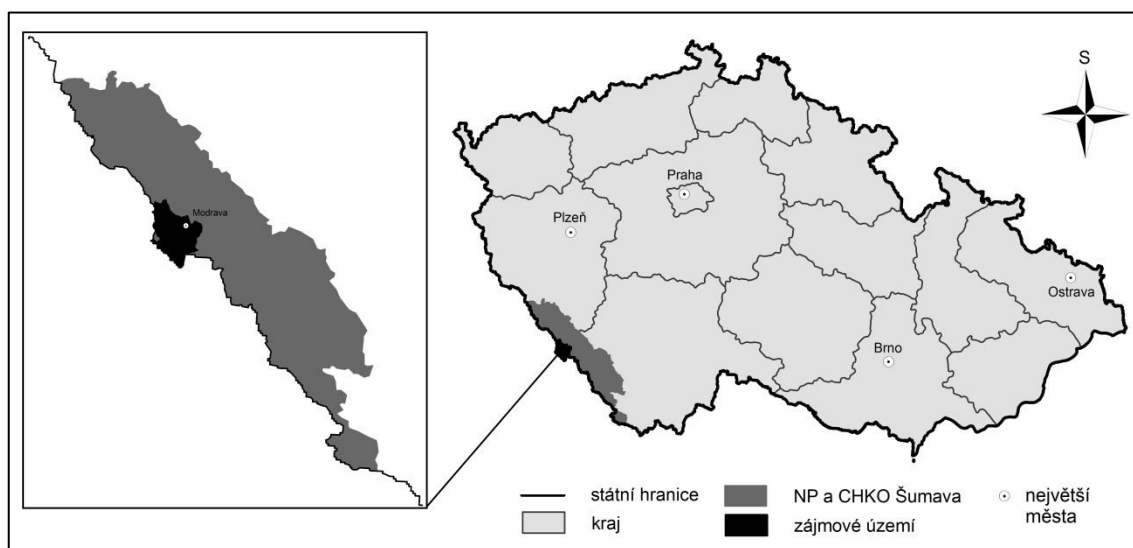
### 3 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ

Zájmové území tvoří povodí horní Vydry, které se nachází v centrální části NP Šumava u hranice s Německem. Zájmová oblast se rozkládá na ploše o velikosti cca 93 km<sup>2</sup> a na jeho území se nachází jediná obec Modrava a samota Březník situovaná jižně od této obce. Nadmořská výška se pohybuje v rozmezí 985-1370 m n. m., přičemž nejnižší položenou lokalitou je právě obec Modrava (985 m n. m.) a nejvyšší místo představuje hora Velká Mokrůvka (1370 m n. m.), která se nachází v jižní části zájmového území na státní hranici s Německem. Dále se zde nacházejí další vrcholy jako například Malá Mokrůvka (1330 m n. m.), Studená hora (1298 m n. m.) nebo Medvědí hora (1223 m n. m.). Většinu zájmového území pokrývají smrkové lesy a slatě a tato lokalita je považována za oblast s největším plošným rozpadem horských smrčín na Šumavě. Situační mapka s umístěním zájmové oblasti v rámci správního členění ČR je zobrazena na obrázku níže (obr. 6). Přehledová mapa celého zájmového území je umístěna v příloze 2 na konci této práce.

NP Šumava byl vyhlášen v roce 1991 a představuje rozsáhlé horské území na jihozápadě České republiky. Dnešní vegetace, která se zde nachází, se od té původní výrazně liší. Původní lesy člověk buď zcela přeměnil, nebo změnil jejich druhové složení. Smíšené porosty nižších poloh tak byly většinou nahrazeny uměle vysázenými smrkovými lesy (Kindlmann, Matějka, Doležal, 2012). Zdravotní stav lesů na Šumavě nejvíce ovlivňuje přemnožení lýkožrouta smrkového (*Ips typographus*) jehož původ lze hledat v letech 1983 a 1984. V této době došlo v sousedním NP Bavorský les v Německu k polomům o rozloze 173 ha, jejichž příčinou byla vichřice. Neodklizené ležící stromy poskytly dobré podmínky pro vývoj lýkožroutů, kteří v roce 1986 napadli i živé stromy. Na české straně byly rozsáhlejší oblasti poškozených stromů kůrovcem zjištěny v roce 1992 a v roce 1995 byla správou NP Šumava vyhlášena bezzásahová zóna na jih od silnice mezi Roklanskou hájenkou a Březníkem. Už v roce 1996 bylo kůrovcem napadeno 80 % této bezzásahové zóny. V druhé polovině 90 let přistoupila správa NP Šumava k holosečné těžbě v okolí bezzásahového pásma s cílem zabránit dalšímu šíření lýkožrouta (Hais, 2009). Šumavské lesy musí poměrně často čelit silným vichřicím a ničivým bouřím. Například počátkem roku 2007 postihl Šumavu orkán Kyril, který způsobil další výrazné polomy (Kučera, 2009). Navíc necelá čtvrtina ze vzniklých vývrátů a polomů (cca 120 000 m<sup>3</sup>) byla ponechána bez zpracování, čímž došlo k největší gradaci lýkožrouta v historii NP. V roce 2010 byly z výše uvedených důvodů zaznamenány dosud nejvyšší kůrovcové těžby (Kahuda, 2011).

Způsob péče o poškozené lesy v této oblasti v posledních letech rozděluje veřejnost, odborníky i politiky. Jádrem mnohaletého sporu je otázka zda v napadených oblastech kácet a případně kde (Kindlmann, Matějka, Doležal, 2012). Střetávají se zde dva hlavní názory na to, jak s poškozenými lesy zacházet. První z nich říká, že poškozené lesy je nutné vykácet a zabránit tak dalšímu šíření kůrovce. Proti němu stojí názor především ekologů, kteří preferují samovolný vývoj lesa bez zásahu člověka. Podle nich je kůrovcová kalamita přirozenou etapou vývoje horského lesa a ten se s ní také sám vyrovná (Šantrůčková, 2010).

*Obr. 6: Situační mapka s umístěním zájmové oblasti v rámci správního členění ČR*



## 4 DATA A METODIKA

### 4.1 Použitá data

Hlavním záměrem této práce bylo, aby využívala datové zdroje, které jsou dostupné pro organizace managementu lesů či ochrany přírody a krajiny. Z tohoto důvodu byla použita lidarová data z Českého úřadu zeměměřického a katastrálního, volně dostupné snímky družice Landsat a družicové snímky SPOT. Snímky SPOT lze za určitých podmínek získat například v rámci iniciativy GMES (*Global Monitoring for Environment and Security*) a nejvíce se podobají datům budoucí mise Sentinel-2, která bude pořizovat multispektrální snímky ve 13 spektrálních pásmech s prostorovým rozlišením 10-60 m.

Primárním datovým zdrojem byly tedy družicové snímky pořízené družicí SPOT 5. Družice SPOT disponují jedním z nejrozsáhlejších archivů snímků pořízených za posledních 25 let. První satelit z řady SPOT byl vypuštěn na oběžnou dráhu v roce 1986. Družice SPOT 5 byla vypuštěna o 16 let později v roce 2002 a v roce 2012 ji následovala družice SPOT 6. Ta se prozatím stala poslední v řadě družic tohoto jména, ale již na rok 2014 je plánováno vypuštění v pořadí již sedmé družice z řady SPOT. Kvůli rychlému vývoji ve zlepšování prostorového rozlišení byla aparatura SPOT 5 několikrát změněna a nakonec byla družice vybavena skenerem HRG (*High Resolution Geometry*), který má prostorové rozlišení 5 m v panchromatickém režimu a 10 m v režimu multispektrálním. Zvláštností je, že družice má 2 HRG senzory, které pořizují řádky s polovičním překrytím. Následným zpracováním je tak možné získat panchromatická data s prostorovým rozlišením 2,5 m. Velikost pořizované scény je 60 x 60 km a časová rozlišovací schopnost družice je 3 dny (Spot Image, 2013).

Pro účel této práce byl použit multispektrální a panchromatický snímek družice SPOT 5, pořízený dne 23. 9. 2005 za téměř nulové oblačnosti. Oba snímky byly poskytnuty ve formátu DIMAP, který slouží pro popis geografických dat. Tento formát se skládá ze dvou částí, jednou pro obraz a druhou pro popis obrazu (metadata). Družicový snímek byl poskytnut ve formátu GeoTIFF, ke kterému byla připojena metadata ve formátu XML (Spot Image, 2013). V metadatach obou použitých snímků byla uvedena úroveň předzpracování 2A. Z dokumentace společnosti Spot Image bylo zjištěno, že tato úroveň zahrnuje umístění snímků do souřadnicového systému UTM (zóna 33N) s referenčním elipsoidem WGS 84. Radiometrické rozlišení snímků bylo 8 bitů. Panchromatický snímek měl prostorové rozlišení 2,5 m a byl nasnímán v 1 spektrálním pásmu s rozsahem od 0,48  $\mu\text{m}$  do 0,71  $\mu\text{m}$ . Multispektrální snímek měl prostorové rozlišení 10 m a byl pořízen ve 4 spektrálních pásmech (*tab. 1*).

Tab. 1: Přehled spektrálních pásem družice SPOT 5 (zdroj: Spot Image, 2013)

	spektrální pásmo	vlnová délka od [μm]	prostorové rozlišení [m]
B1	viditelné zelené (GREEN)	0,50 – 0,59	10
B2	viditelné červené (RED)	0,61 – 0,68	10
B3	blízké infračervené (NIR)	0,78 – 0,89	10
B4	střední infračervené (SWIR)	1,58 – 1,75	10

Dalším datovým zdrojem byl snímek družice Landsat 5. Ten byl použit za účelem přiblížení se k datu pořízení lidarových dat. Vzhledem k tomu, že snímek SPOT byl pořízen o 5 let dříve než data LLS, byl použit ještě snímek pořízený družicí Landsat 5 ke dni 12. 9. 2010, který se s rokem pořízení LLS dat shoduje. Snímek Landsat byl stažen z webových stránek organizace USGS (*U. S. Geological Survey*), kde jsou tato data po zaregistrování volně k dispozici. Družice Landsat 5 byla vypuštěna na oběžnou dráhu v roce 1984. Je vybavena skenerem TM (*Thematic Mapper*), který snímá v 7 spektrálních pásmech, jejichž vlastnosti jsou uvedeny v tabulce 2. Prostorové rozlišení snímků je 30 m a 120 m (v pásmu TIR). Družicové snímky Landsat jsou poskytovány ve formátu GeoTIFF, ve kterém je každé pásmo uloženo jako samostatný soubor typu TIFF. Složka rovněž obsahuje metadata k danému snímku, ze kterých bylo zjištěno, že snímek byl umístěn do souřadnicového systému UTM s referenčním elipsoidem WGS 84.

Tab. 2: Přehled spektrálních pásem družice Landsat 5 TM (zdroj: Gsat, 200-?)

	spektrální pásmo	vlnová délka od [μm]	prostorové rozlišení [m]
B1	viditelné modré (BLUE)	0,45 – 0,52	30
B2	viditelné zelené (GREEN)	0,52 – 0,60	30
B3	viditelné červené (RED)	0,63 – 0,69	30
B4	blízké infračervené (NIR)	0,76 – 0,90	30
B5	střední infračervené (SWIR)	1,55 – 1,75	30
B6	termální infračervené (TIR)	10,42 – 12,50	120
B7	střední infračervené (SWIR)	2,08 – 2,35	30

Jako další významný zdroj informace byla použita data leteckého laserového skenování (LLS). Strukturní vlastnosti lesa je možné zjišťovat také jen z lidarových dat samotných, ale v takovém případě je nutné mít k dispozici data s vysokou hustotou zaznamenaných bodů. Velkou nevýhodou takových dat bývá ovšem jejich vysoká pořizovací cena. Jako vhodný kompromis se tak jeví kombinace trojrozměrných dat LLS s nižší hustotou bodů a dvojrozměrných multispektrálních dat pro získání spektrální informace (Dalponte, 2012). Pro tuto práci byla proto použita data LLS pořízená v roce 2010 v rámci tvorby nového výškopisu ČR. Tato data byla poskytnuta Českým úřadem zeměměřickým a katastrálním ve formátu XYZ a byla zakoupena v rámci grantu k projektu GAČR (P209/12/0997) s názvem “Vliv disturbancí horské krajiny na dynamiku fluvialních procesů”. Skenování bylo prováděno z výšky kolem

1 500 m nad terénem a výsledné bodové mračno má nízkou hustotu bodů (přibližně 1,3 bodu/m<sup>2</sup>). Družicová data SPOT se bohužel nepodařilo získat ke stejnému roku jako data LLS, tudíž je mezi oběma druhy dat časový rozestup 5 let. Z tohoto důvodu byl použit ještě snímek Landsat z roku 2010.

Posledním typem dat, která byla použita jako pomocná, byla vektorová data ZABAGED (*Základní báze geografických dat*) a archivní ortofoto České republiky z roku 2005 a 2011. Tato data byla poskytnuta zdarma Českým úřadem zeměměřickým a katastrálním. Data ZABAGED byla v této oblasti aktualizována k roku 2012 a použita byla pro tvorbu masky lesních porostů. Ortofoto ČR posloužilo k hodnocení přesnosti klasifikace.

## 4.2 Použitý software

Pro zpracování dat byl nejvíce využíván software eCognition Developer Trial 8.8 a eCognition Developer 8.7. Jedná se o program pro objektově orientované vyhodnocení obrazových dat a je určen především pro vytváření a vývojází pro objektovou klasifikaci. Obsahuje kompletní řadu funkcí a nástrojů zaměřených na segmentaci a následnou klasifikaci (Gisat, 200-?). V tomto programu byla provedena právě segmentace obrazu a vytvořena klasifikační báze.

Často využívaný byl také software PCI Geomatica 9.1, který je určený pro práci s geografickými daty. Program je zaměřen především na zpracování rastrového obrazu a je proto velmi často využíván pro zpracování družicových a leteckých snímků (Gisat, 200-?). Pomocí tohoto software bylo provedeno například předzpracování družicových snímků.

Pro zpracování dat leteckého laserového skenování byl použit software E3De (nebo také Envi Lidar). Ten poskytuje interaktivní prostředí pro získávání trojrozměrných informací z lidarových dat a umožňuje export výsledků pro další analýzu. Program podporuje soubory ve formátu LAS i ASCII a lze díky němu získat z dat LLS například digitální model terénu (DEM) nebo digitální model povrchu (DSM).

Především pro vizualizaci výsledků byl použit program ArcGIS 10.1, který je tvořený řadou produktů pro vytváření, správu, analýzu a vizualizaci geografických dat. Nejvíce byly využívány moduly ArcMap a ArcCatalog. Kromě výše uvedených programů byl dále použit Microsoft Office Word 2010 a Microsoft Office Excel 2010, a to zejména pro tvorbu textové části práce a tabulek.

## 4.3 Předzpracování družicových snímků

Družicové snímky pořízené družicí SPOT 5 byly před objektovou klasifikací předzpracovány. V prvním kroku byly oba snímky (multispektrální i panchromatický) oříznuty podle hranice zájmového území. K tomu byla použita funkce *clipping/subsetting* v programu PCI Geomatica modul Focus.

Jak již bylo uvedeno výše, multispektrální snímek má prostorové rozlišení 10 m a panchromatický 2,5 m (tedy 4x vyšší). Díky pansharpeningu lze multispektrální snímek zaostřit snímkem panchromatickým a získat tak multispektrální snímek s prostorovým rozlišením 2,5 m. Tato metoda sice pravděpodobně nezlepší multispektrální informaci u získaných menších pixelů, ale ty mohou vést k lepším výsledkům při segmentaci obrazu. K provedení pansharpeningu byl opět využit software PCI Geomatica modul Focus. V knihovně algoritmů je zde k dispozici funkce *PANSHARP: Automatic Image Fusion*, která slouží právě k zaostřování multispektrálního snímku panchromatickým. Na obrázku 7 je ukázka původního a zaostřeného multispektrálního snímku. Oříznutý a zaostřený multispektrální snímek byl uložen ve formátu PCIDSK.

*Obr. 7: Původní (vlevo) a zaostřeny (vpravo) multispektrální snímek SPOT*



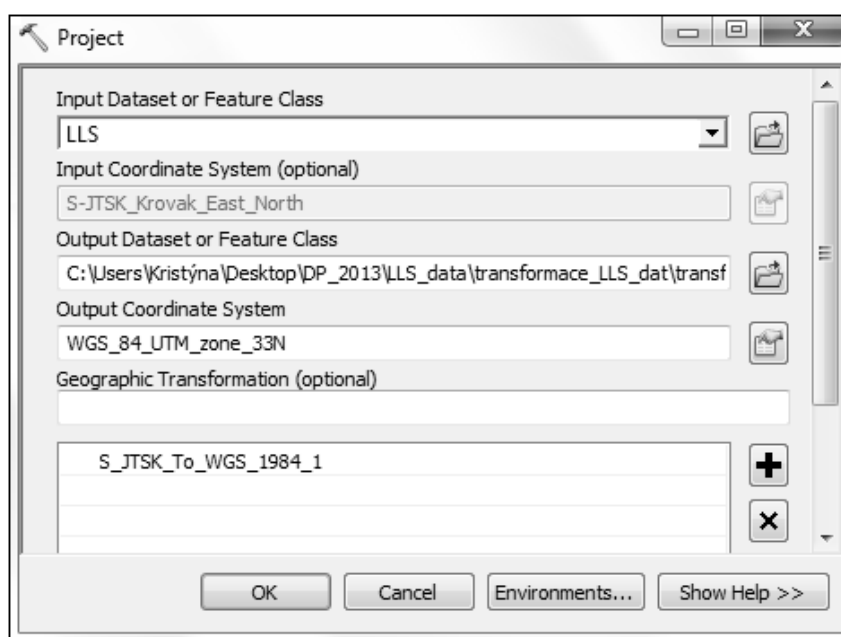
Snímek Landsat byl poskytnut ve formátu GeoTIFF, ve kterém bylo každé pásmo uloženo samostatně. Z důvodu pohodlnější práce s daty bylo nutné tato pásma spojit do jednoho souboru. K tomu byl použit program PCI Geomatica modul Focus funkce *Data Merge*. Při této operaci byla vybrána vstupní pásma, zadán název a umístění výstupního souboru PCIDSK, zvolen souřadnicový systém UTM s referenčním elipsoidem WGS 84 a ponechána velikost pixelu 30 m. Vytvořený soubor byl oříznut podle hranice zájmového území pomocí funkce *clipping/subsetting* ve stejném programu.

#### **4.4 Předzpracování dat LLS**

Data LLS byla poskytnuta ve formátu XYZ a byla umístěna do souřadnicového systému S-JTSK Krovak, East North. Multispektrální družicové snímky jsou však umístěny do souřadnicového systému UTM (zóna 33N) s referenčním elipsoidem WGS 84. Bylo tedy nutné souřadnicový systém obou typů dat sjednotit. Proto byla provedena transformace dat LLS do

souřadnicového systému UTM (zóna 33N) s referenčním elipsoidem WGS 84. Nejprve byla tato data ve formátu XYZ načtena do programu ArcGIS modul ArcMap pomocí funkce *ASCII 3D to Feature Class* a uložena jako shapefile do geodatabáze. Pro samotnou transformaci byla použita funkce *Project*, ve které byl nastaven původní a požadovaný souřadnicový systém (obr. 8). Transformované bodové vrstvy byly převedeny zpět do formátu XYZ pomocí funkce *Feature Class Z to ASCII*. Tím byla data LLS připravena pro práci v programu E3De. Výše uvedený postup transformace bylo nutné aplikovat celkem na 33 mapových listů, ve kterých byla LLS data poskytnuta. Vzhledem k velkému objemu dat (cca 8 GB) představovala jejich transformace i následné zpracování poměrně časově náročný proces.

Obr. 8: Nastavení parametrů funkce *Project* pro transformaci dat LLS



## 4.5 Zpracování dat LLS

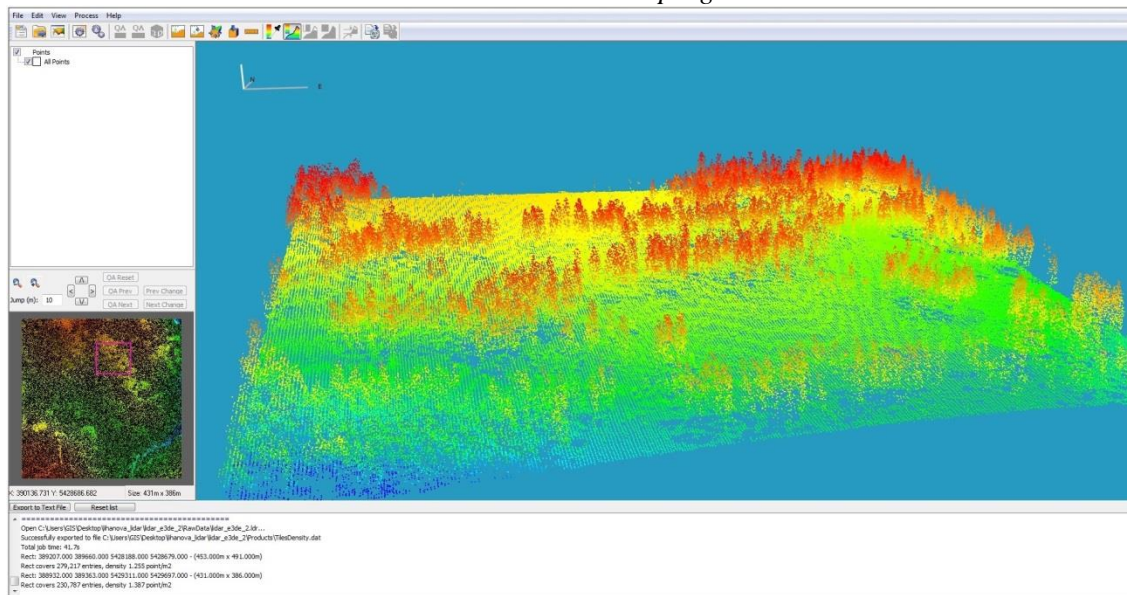
Cílem zpracování dat LLS bylo získat rastr DEM a DSM a z nich následně vytvořit rastr nDSM, který nese informaci o výšce objektů na zemském povrchu. Pro tento účel byl použit software E3De, ve kterém byl nejprve založen nový projekt, do kterého byla importována lidarová data ve formátu XYZ. U importovaných souborů bylo potřeba manuálně přiřadit jednotlivé sloupce k souřadnicím X, Y a Z a také definovat souřadnicový systém UTM (zóna 33N). Pokud by data LLS byla ve formátu LAS, tento krok by odpadl, protože potřebné informace bývají obsaženy v hlavičce tohoto souboru. Po nastavení uvedených parametrů byla data LLS zobrazena v hlavním okně programu (obr. 9).

Dle doporučení uvedeného v manuálu programu byla před samotným zpracováním dat vygenerována mapa hustoty bodů (obr. 10) pomocí funkce *Generate Density Map*. Důvodem tohoto doporučení je fakt, že ne všechna data LLS jsou vhodná pro vytváření všech výstupů,




kteřé software nabízí. Jednou z těchto funkcí je například generování budov a stromů, které se doporučuje až u dat s hustotou vyšší než 6 až 8 bodů na metr čtvereční. Díky této funkci bylo zjištěno, že průměrná hustota bodů je 1,3 bodu/m<sup>2</sup>.

Obr. 9: Data LLS zobrazená v programu E3De




Obr. 10: Ukázka hustoty bodů LLS vygenerovaná v programu E3De



Dalším krokem bylo vygenerování digitálního modelu terénu (DEM) a digitálního modelu povrchu (DSM) pomocí funkce *Process All Data*. Po spuštění této funkce bylo automaticky otevřeno okno s nastavením (*Project Properties*), ve kterém byly nastaveny všechny požadované parametry, jejichž přehled je umístěn v Příloze 4. DEM a DSM (obr. 11) byly vygenerovány s prostorovým rozlišením 2 m a uloženy ve formátu TIFF do složky projektu. Digitální model terénu DEM (*Digital Elevation Model*) je rastr, jehož hodnoty buněk odpovídají nadmořským výškám holého zemského povrchu bez objektů na něm. Digitální model povrchu


DSM (*Digital Surface Model*) obsahuje nadmořské výšky zemského povrchu a vrchních ploch objektů na něm (např. střechy budov, koruny stromů). Výše uvedený postup pro získání DEM a DSM musel být opakován pro všechny mapové listy, ve kterých byla data LLS poskytnuta. Celkem se jednalo o 33 mapových listů, z nichž každý byl tímto způsobem v programu E3De zpracován. Digitální model povrchu stejně tak jako digitální model terénu byl tedy z programu E3De získán v podobě 33 rastrových souborů. Tyto rastry byly spojeny do jednoho souboru, který pokrývá celé zájmové území a oříznuty jeho hranicí. Pro spojení všech rastrů byla použita funkce *Mosaic to new raster* v programu ArcGIS modul ArcMap. Tím bylo všech 33 mapových listů spojeno do jednoho rastru pro DEM a jednoho rastru pro DSM. Oba rastry byly oříznuty hranicí zájmového území pomocí funkce *Clipping/Subsetting* v programu Geomatica modul Focus.

Obr. 11: Výřez DEM (vlevo) a DSM (vpravo) vygenerovaný v programu E3De



Dále bylo potřeba z rastrů DSM a DEM získat normalizovaný digitální model povrchu nDSM (*Normalized Digital Surface Model*). Tento rastr obsahuje hodnoty výšek nadzemních objektů a je získán rozdílem DSM a DEM. Pro tvorbu nDSM byl použit program PCI Geomatica modul Focus, ve kterém byl od rastru DSM odečten rastr DEM pomocí funkce *Raster Calculator*. Výsledný rastr nDSM jehož celý náhled je umístěn v příloze 5 byl uložen ve formátu TIFF s prostorovým rozlišením 2 m. Výřez z výsledného rastru nDSM je zobrazen na obrázku 12. Ukázky DEM, DSM a nDSM uvedené na obrázcích a v příloze byly vytvořeny v programu ArcMap, který z neznámého důvodu neumožnil jiné než defaultní nastavení barevného zobrazení. Z tohoto důvodu jsou tyto ukázky pouze černobílé a zobrazené pouze pro vytvoření představy o výstupech z programu E3De (Envi Lidar).

Obr. 12: Výřez normalizovaného digitálního modelu povrchu (nDSM)



## 4.6 Stanovení klasifikačního systému

Před samotnou klasifikací vytvořených segmentů je třeba definovat klasifikační třídy, do kterých budou segmenty zařazovány. Ve většině odborné literatury jsou lesy na základě jejich zdravotního stavu klasifikovány pouze do dvou maximálně tří tříd. Důvodem nižšího počtu klasifikovaných tříd v odborné literatuře může být například to, že je využíván vždy pouze jeden typ dat. Předpokladem bylo, že díky použití multispektrálního družicového snímku doplněného o výškovou informaci z dat LLS bude možné těchto tříd rozlišit více.

Při tvorbě klasifikačního systému bylo nutné zohlednit charakter zájmového území a také vlastnosti použitých dat. V zájmové oblasti se nachází jak zdravé, tak poškozené lesní porosty. Vzhledem k tomu byly stanoveny celkem 4 klasifikační třídy podle stupně poškození lesa, přičemž poslední z nich je rozdělena na další dvě podtřídy. Pro představu jsou v příloze 7 umístěny fotografie, představující zástupce k jednotlivým třídám. Klasifikace lesa podle takto definovaného klasifikačního systému by mohla poskytnout přínosné informace například pro hydrologii, lesní management, správu národního parku nebo ochranu přírody a krajiny. Informace získané takovouto klasifikací by se mohly uplatnit například při hodnocení odtokových poměrů, sledování vývoje poškození a stanovení nejohroženějších oblastí.

*Třída 1* představuje oblasti se silně poškozeným lesem, ve kterém jsou suché stromy buď odtěženy, nebo jsou popadány na zemi. Nenachází se zde vzrostlá vegetace, avšak mohou se zde nacházet pahýly uschlých stromů, které jsou ovšem zastoupeny velmi řídko. Na družicovém snímku se tyto oblasti mohou jevit jako holá půda bez vegetace a průměrná výška vegetace je minimální.

*Třída 2* jsou oblasti lesa s poškozenými stojícími suchými stromy s vyšší hustotou zastoupení, které nebyly odtěženy. Tato třída je charakterizována vyšší hustotou lesní vegetace než třída předchozí (cca 20 – 50 %). Také průměrná výška těchto oblastí je o něco vyšší než u

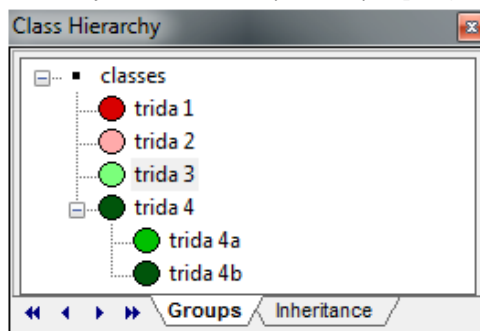
předchozí kategorie. V důsledku toho, že jsou stromy silně poškozené, na družicovém snímku se příliš neprojevují, zkoumané území se může jevit podobně jako holá půda.

*Třída 3* zastupuje oblasti, ve kterých se nacházejí suché poškozené avšak vzrostlé stromy společně se stromy zdravými. Jedná se tedy o území se smíšeným zdravým a narušeným lesem. Hustota stromů dosahuje vyšších hodnot (cca 50 – 80 %). Pod vzrostlými poškozenými stromy se může vyskytovat zdravý podrost s nově obnovujícími se stromy. Na družicovém snímku se projevuje vliv vegetace, avšak zastoupený poškozený les snižuje hodnoty odrazivosti v relevantních pásmech.

*Třída 4* představuje zdravý nepoškozený les (bez zjevných příznaků poškození) s vysokou hustotou stromů. Tato třída je dále rozdělena na třídu 4a a třídu 4b podle výšky vegetace. První třída 4a představuje les s průměrnou výškou do 5m, který je v růstu a tvoří jej například obnovující se stromy. Druhá třída zahrnuje les, jehož průměrná výška je vyšší a tedy tvořen stromy staršími.

Téměř na celém zájmovém území se nacházel jehličnatý les a pouze na 3 místech, o přibližné rozloze 0,55 km<sup>2</sup>, se nacházel les smíšený. Tyto oblasti byly do klasifikace rovněž zařazeny. Před tvorbou klasifikační báze bylo nutné všechny třídy v programu eCognition vytvořit. K tomuto účelu slouží panel *Class Hierarchy*, ve kterém byla zvolena možnost Insert Class a v otevřeném okně určeno vždy jméno třídy a přiřazena barva. Vytvořené klasifikační schéma v programu eCognition je na obrázku 13.

Obr. 13: Přehled klasifikačních tříd vytvořený v programu eCognition



## 4.7 Objektově orientovaná klasifikace

Po předzpracování družicových snímků a zpracování dat leteckého laserového skenování mohlo být přistoupeno k objektově orientované klasifikaci. Ta byla provedena v programu eCognition Developer 8.7, ve kterém byl založen nový projekt. Do tohoto projektu byl načten družicový snímek SPOT/Landsat a navíc jedno pásmo s rastrem nDSM získaným z dat LLS. Objektová klasifikace byla prováděna pouze pro oblasti lesa a ostatní krajinný povrch byl z klasifikace vypuštěn. Z tohoto důvodu byla vytvořena maska lesních oblastí. K tomuto účelu byla využita vektorová vrstva ZABAGED, ze které byla vytvořena vrstva obsahující nelesní oblasti a ta byla




pomocí funkce *Erase* v programu ArcMap vyjmuta z vrstvy zájmového území. Oblasti, které byly z klasifikace vyjmuty spolu s družicovými snímky, jsou znázorněny v přílohách 3 a 4.

#### 4.7.1 Segmentace


Segmentace obrazu představuje první krok při objektově orientované klasifikaci. Jejím cílem je rozdělit družicový snímek do relativně homogenních objektů. Program eCognition nabízí několik typů segmentačních algoritmů. Z nabídky byla zvolena multiměřítková segmentace (*multiresolution segmentation*). U tohoto typu segmentace je důležité vhodně nastavit její parametry. Toto nastavení záleží vždy na zvolené metodice a autorově posouzení. Prvním z parametrů jsou váhy jednotlivých spektrálních pásem (*Image Layer Weights*), které byly ponechány na hodnotě 1 pro všechna spektrální pásma. Pásmo nDSM nebylo do segmentace zahrnuto a jeho váha byla nastavena na hodnotu 0. Druhým parametrem, který program umožňuje zvolit, je měřítkový parametr (*Scale Parametr*). Velikost měřítkového parametru nepřímo ovlivňuje velikost výsledných objektů a to tak, že čím je jeho hodnota vyšší, tím větší jsou vytvořené segmenty. Tuto hodnotu je nutné volit pečlivě, protože nastavením příliš vysokého měřítkového parametru může dojít ke generalizaci a ztrátě informace. Vyzkoušeny byly různé hodnoty tohoto parametru (*obr. 14*) a jako nejlepší byla zvolena hodnota 30 pro snímek SPOT a hodnota 35 pro snímek Landsat, která vedla k objektům použitelným pro další klasifikaci.

*Obr. 14: Ukázka původního (vlevo nahoře) a segmentovaného snímku SPOT s měřítkovým parametrem 20 (vpravo nahoře), 30 (vlevo dole) a 40 (vpravo dole)*



Dalším nastavitelným parametrem je váha tvarového kritéria (*shape*), na jejímž základě je pak dopočtena hodnota spektrálního kritéria jako doplněk do 1. Při vysoké hodnotě pro spektrální kritérium dochází k vytváření objektů s nepřírodným tvarem hranic. Pokud je ovšem nastavena vysoká hodnota pro tvarové kritérium, objekty často obsahují pixely s na první pohled odlišnou spektrální informací. Z tohoto důvodu je nutné zvolit hodnoty přiměřeně tak, aby výsledné objekty měly přijatelný tvar a zároveň v nich nebyly pixely s naprosto odlišnou spektrální informací. Obrázek 15 ukazuje rozdíl v segmentaci při zvolení vysoké a nízké váhy pro tvarové kritérium. Pro segmentaci snímku SPOT byly použity hodnoty 0,3 pro tvarové kritérium a 0,7 pro spektrální kritérium. U snímku Landsat byla použita hodnota 0,2 pro tvarové kritérium a 0,8 pro kritérium spektrální.

*Obr. 15: Segmentace snímku SPOT s vysokou váhou tvarového kritéria (vlevo) a naopak s vysokou váhou spektrálního kritéria (vpravo)*



Posledním nastavitelným parametrem je váha pro kompaktnost (*compactness*), podle které je dopočtena váha pro hladkost jako doplněk do 1. Vysoká hodnota váhy pro kompaktnost vede k tvorbě objektů, které měly velmi podobný čtvercový až kruhový tvar a ve kterých byly spojeny na první pohled odlišné třídy. Naopak při zvolení vysoké hodnoty pro hladkost dochází k tvorbě velmi tvarově složitých objektů. Po vyzkoušení několika kombinací byla u snímku SPOT váha pro kompaktnost nastavena na hodnotu 0,4 a u snímku Landsat na hodnotu 0,3.


Zaostřený multispektrální snímek družice SPOT 5 s prostorovým rozlišením 2,5 m byl pomocí multiměřítkové segmenatce rozdělen na jednotlivé objekty. Stejně tak tomu bylo následně i u multispektrálního snímku Landsat s prostorovým rozlišením 30 m. Přehled použitých parametrů obou segmentací je uveden v tabulce 3 a výřez z výsledných segmentací je zobrazen na obrázku 16.



Tab. 3: Hodnoty parametrů použité při multiměřítkové segmentaci snímku SPOT a Landsat

	SPOT	Landsat
parametr	hodnota	hodnota
váhy spektrálních pásem	1, 1, 1, 1	1, 1, 1, 1, 1, 1
měřítkový parametr	30	35
váha pro tvarové kritérium	0.3	0.2
váha pro spektrální kritérium	0.7	0.8
váha pro kompaktnost	0.4	0.3
váha pro hladkost	0.6	0.7

Obr. 16: Výřez z výsledné segmentace snímku SPOT (vlevo) a Landsat (vpravo)

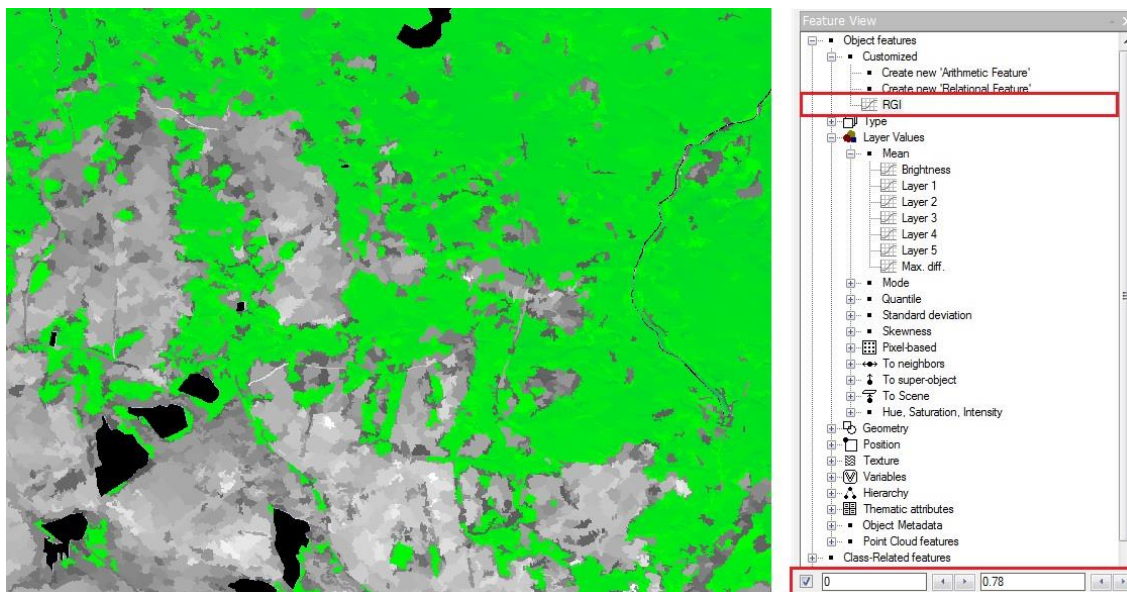


#### 4.7.2 Tvorba klasifikační báze

Klasifikace družicových snímků byla provedena tvorbou klasifikační báze, při které dochází k určování prahových hodnot. Tato metoda představuje tzv. tvrdou klasifikaci, při které je rozhodnuto, zda objekt do dané třídy patří nebo nepatří. V programu eCognition pro tvorbu klasifikační báze slouží panel *Process Tree*, ve kterém se pomocí funkce *Append New* vytvářejí vlastní klasifikační pravidla. Po aplikaci těchto pravidel je potřeba zkontrolovat výsledky. Pokud výsledek není uspokojivý je nutné pravidla upravit. Tento proces se opakuje tak dlouho, dokud není dosaženo uspokojivých výsledků (Trimble, 2013).

Pro stanovení vhodné prahové hodnoty lze využít panel *Feature View*, ve kterém je možné u jednotlivých příznaků posouvat práh hodnot. Segmenty, které tento požadavek splňují, jsou na družicovém snímku označeny barevně (obr. 17). Při stanovení nejvhodnější prahové hodnoty je použit nástroj *assign class*, který všechny segmenty s požadovanou hodnotou zařadí do zvolené klasifikační třídy.

Obr. 17: Ukázka nastavení prahové hodnoty indexu RGI v panelu Feature View



V prvním kroku klasifikace snímku SPOT byly klasifikovány zdravé lesy (třída 4). K tomuto účelu byly vypočteny indexy RGI a NDVI. Přidání vlastních charakteristik se v programu eCognition provádí v panelu *Feature View* v záložce *Object Features Customized* pomocí funkce *Create New Arithmetic Feature*. Zde byly vypočteny oba indexy podle níže uvedených vzorců.

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

$$RGI = \frac{RED}{GREEN}$$

Tyto indexy byly zvoleny na základě studia relevantní literatury, kdy např. Coops et al. (2006) nebo Hicke a Logan (2009) pomocí těchto indexů došli k poměrně dobrým výsledkům klasifikace lesní vegetace pomocí multispektrálních dat. K vymezení zdravých lesních porostů byl po otestování obou indexů jako vhodnější zvolen index RGI. Tento index byl již v několika odborných článcích úspěšně použit pro klasifikaci lesa podle jeho zdravotního stavu. Jedná se o jednoduchý poměr červeného a zeleného spektrálního pásma. Jeho aplikace spočívá ve zvýraznění barevné změny od zelené k červené, která značí nenávratné poškození stromu. Jako prahová hodnota oddělující zdravé lesy od poškozených byla zvolena hodnota RGI = 0,78. Tato hodnota byla stanovena pomocným sběrem trénovacích ploch, na základě kterého byl vytvořen přehled o hodnotách jednotlivých charakteristik. Objekty, jejichž hodnota RGI byla nižší, představovaly zdravé lesní porosty bez vizuálních příznaků poškození. Při kontrole výsledků toto rozdělení poměrně dobře korespondovalo s reálným stavem.

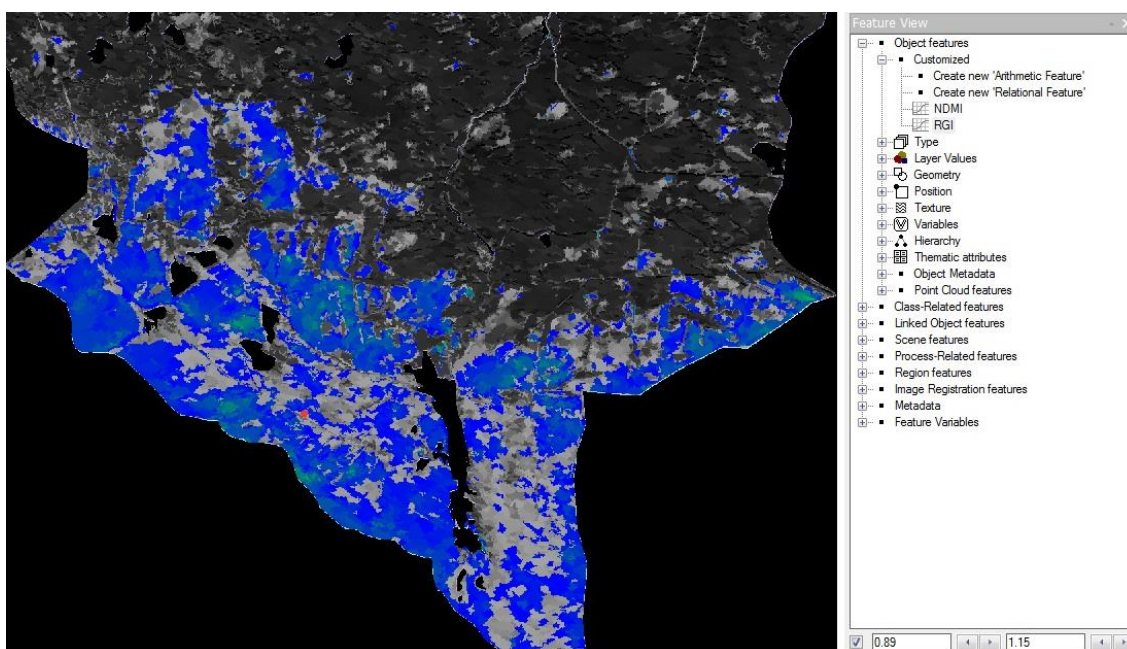
Třída 4 byla v závěru klasifikační báze ještě rozlišena na třídu 4a a třídu 4b podle průměrné výšky vegetace. Průměrná výška byla v programu eCognition vypočítána pro každý segment jako průměr z hodnot výšky v každém pixelu obsaženém v segmentu. Jako hraniční hodnota mezi oběma třídami byla zvolena hodnota průměrné výšky 5 metrů. Zdravé lesy s průměrnou



výškou do 5 m byly zařazeny do třídy 4a a představují lesy v počátečních stádiích růstu. Může se jednat o lesy, které se samovolně obnovují nebo například o nově vysázené stromy po odtěžení. Lesní oblasti s vyšší výškou představují již vzrostlé lesy, které pokud se nacházejí v blízkosti lesů poškozených, mohou být s velkou pravděpodobností také ohroženy. Tento fakt je dán tím, že lýkožrout smrkový, který se v této oblasti nachází, přednostně napadá především starší stromy s větší tloušťkou kmenů. Pokud tedy zdravý vzrostlý les sousedí s lesem napadeným, jeho ohrožení je vyšší než u lesa mladšího se slabými kmeny.

Jako další byla hledána pravidla pro klasifikaci třídy 1. U této třídy bylo předpokladem, že se na družicovém snímku bude jevit téměř jako holá půda bez vegetace. Hodnoty indexu RGI by tedy měly být nejvyšší a podíl zelené vegetace naopak nejnižší. Pouze při použití spektrálních informací se však tuto kategorii nepodařilo odlišit od kategorie 2, která má podobné vlastnosti. Při zvolení prahových hodnot indexu RGI se do třídy 1 zařadily i segmenty, které podle ortofota spadají do třídy 2 (obr. 18). Z tohoto důvodu byla prahová hodnota indexu RGI doplněna o informaci o průměrné výšce, která pomohla tyto třídy od sebe odlišit.


Obr. 18: Vymezení třídy 1 pouze na základě indexu RGI na snímku SPOT



Předpokladem bylo, že průměrná výška třídy 1 bude minimální, protože se jedná o třídu s odtěženými nebo popadanými poškozenými stromy. Případně se zde mohou nacházet pahýly suchých stromů, které jsou však tak řídké rozmístěny, že se na průměrné výšce téměř neprojeví. Do třídy 1 byly tedy zařazeny objekty splňující předchozí podmínku a navíc je jejich průměrná výška za segment nižší než 0,4 m. Ostatní objekty, které tyto pravidla nesplňují, byly převedeny


do třídy *unclassified*. Změna v klasifikaci třídy 1 přidáním výškové informace je patrná z obrázku 19.

*Obr. 19: Vymezení třídy 1 na základě indexu RGI a informací o výšce*




Následovala klasifikace třídy 2. Z klasifikace předchozí třídy již bylo zjištěno, že její spektrální vlastnosti jsou velmi podobné třídě 1 a k jejímu odlišení je potřeba zahrnout informaci o výšce. Jelikož třída 2 zahrnuje oblasti s poškozenými lesy, ve kterých se nacházejí převážně stojící suché stromy, její průměrná výška vegetace by měla být vyšší než u třídy 1. Z doposud neklasifikovaných segmentů byly vybrány ty, jejichž hodnota RGI se pohybuje v rozmezí 0,88 až 1,15 a jejichž průměrná výška je zároveň vyšší než 0,4 m. Segmenty odpovídající těmto pravidlům byly zařazeny do třídy 2 (obr. 20) a zbylé segmenty byly opět převedeny do třídy *unclassified*.

*Obr. 20: Vymezení třídy 2 na základě indexu RGI a informací o výšce*



Jako další následovala klasifikace třídy 3. Vzhledem k tomu, že tato třída představuje lesní oblasti, ve kterých se nacházejí zdravé stromy společně se stromy poškozenými a suchými, měla by hodnota indexu RGI být vyšší než u zdravého lesa. Z doposud neklasifikovaných objektů byly vybrány ty, jejichž RGI je větší než 0,78. Výška vegetace u třídy 3 může být různá vzhledem k tomu, že zdravé stromy mohou být vysoké nebo se může naopak jednat o nižší obnovující se lesní porost. Vyzkoušeno bylo několik prahových hodnot a na základě vizuálního porovnání s ortofotem byla jako minimální průměrná výška zvolena hodnota 0,7 m. Takto klasifikovaná třída 3 je zobrazena na obrázku 21.

Obr. 21: Vymezení třídy 3 na základě indexu RGI a informací o výšce



Po aplikaci všech dosud vytvořených pravidel zbylo několik objektů, které nebyly zařazeny do žádné třídy. Některé z neklasifikovaných segmentů velkou částí své hranice sousedily se segmenty klasifikovanými. Předpokladem tedy bylo, že sdílí-li neklasifikovaný objekt velkou část své hranice s objektem klasifikovaným do určité třídy, měl by být také zařazen do této třídy. K tomuto účelu byla použita charakteristika *Relative border to*, která se nachází ve skupině *Class-Related Features*. Tato funkce popisuje u všech segmentů délku celkové hranice objektu ke hranici k určité třídě. Tato charakteristika byla vypočtena pro všechny dosud klasifikované třídy. Pokud segment s vybranou třídou nesousedí, je hodnota této charakteristiky 0. Pokud je segment zcela ohraničen vybranou třídou, je hodnota *Relative border* 1. Hodnoty blíží se 1 svědčí o větším podílu společné hranice s vybranou třídou a hodnoty blíží se 0 naopak. Do klasifikační báze byla doplněna pravidla, která říkají, že má-li segment hodnotu této charakteristiky větší než 0,5 k určité třídě, bude rovněž do této třídy zařazen.

I po aplikování těchto pravidel zbylo menší množství neklasifikovaných segmentů (452), které nesplňovaly žádné z předchozích definovaných pravidel. Tyto segmenty jsem se rozhodla klasifikovat na základě hodnot NDVI a na základě vizuálního srovnání s ortofotem. Segmenty, jejichž hodnoty NDVI byla menší než 0,1 a průměrná výška vegetace menší než 0,4 m byly



zařazeny do třídy 1. Segmenty se stejnou hodnotou NDVI, ale s průměrnou výškou vyšší než 0,4 m byly zařazeny do třídy 2. Segmenty, jejich hodnota NDVI se pohybovala v rozmezí od 0,1 do 0,15, byly zařazeny do třídy 3 a segmenty s hodnotou tohoto indexu vyšší než 0,15 byly zařazeny do třídy 4. Přehled všech prahových hodnot je uveden v Příloze 8.

Stejným způsobem byla vytvořena klasifikační báze i pro klasifikaci multispektrálního snímku Landsat s tím rozdílem, že kromě indexu RGI byly použity i hodnoty ve spektrálním pásmu NIR. Snímek byl opět klasifikován do 5 tříd. Zdravé lesy (třída 4) byly vymezeny na základě indexu RGI a v závěru práce rozděleny podle jejich výšky do třídy 4a a 4b na základě průměrné výšky v jednotlivých segmentech. Pro definování třídy 1 a 2 se jako nejvhodnější jevíly hodnoty ve spektrálním pásmu NIR. Ty byly pro obě třídy velmi podobné a jejich oddělení proto bylo realizováno na základě průměrné výšky. Následovalo definování třídy 3 za použití indexu RGI a průměrné výšky. Po aplikování dosavadních pravidel zbylo několik neklasifikovaných segmentů, které byly opět klasifikovány pomocí charakteristiky *Relative border to*. I po provedení těchto pravidel zbylo velmi malé množství segmentů (32), které nebyly zařazeny do žádné třídy. Rozhodla jsem se tyto segmenty zařadit na základě průměrné hodnoty Greenness, která byla získána provedením transformace Tasseled Cap. Přehled použitých prahových hodnot je uveden v Příloze 9.

Kompletní klasifikační báze pro oba družicové snímky jsou umístěny v přílohách 8 a 9 i v digitální podobě na přiloženém CD. Konečné výsledky obou objektově orientovaných klasifikací byly z programu eCognition exportovány ve formátu TIFF i ve formátu SHP. V programu ArcGIS modul ArcMap byly vytvořeny výsledné mapové výstupy. Ty jsou umístěny v Přílohách 10 a 11.

## 4.8 Hodnocení přesnosti klasifikace

Důležitou součástí klasifikačního procesu je i hodnocení přesnosti klasifikace, při kterém jsou její výsledky porovnávány s referenčními daty. Referenční data mohou být pořízena buď pomocí terénního průzkumu, nebo mohou pocházet z jiných zdrojů. V mém případě bylo jako referenční použito archivní barevné ortofoto ze stejného roku jako družicový snímek SPOT. Toto ortofoto bylo poskytnuto Českým úřadem zeměměřickým a katastrálním a jeho prostorové rozlišení je 0,5 m. Při hodnocení přesnosti klasifikace je porovnáváno, zda objekt představující určitou třídu v referenčních datech byl do stejné třídy také klasifikován (Congalton, 1991).

Nejčastější metodou pro hodnocení přesnosti klasifikace je vypočtení tzv. chybové matice (*Error matrix*), která byla použita i v této práci. Tato metoda porovnává u všech tříd referenční data s výsledky klasifikace (Dobrovolný, 1998). Chybová matice je vždy čtvercová, v níž počet řádků i sloupců odpovídá počtu tříd. Správně klasifikovaná data se nacházejí na hlavní diagonále této matice a ostatní hodnoty mimo tuto diagonálu jsou chyby. Z chybové matice lze

vypočíst tzv. celkovou přesnost jako podíl součtu všech hodnot na diagonále k celkovému počtu testovaných objektů. Problémem celkové přesnosti je to, že se jedná o průměrnou hodnotu. Nedokáže proto odhalit, zda byly chyby rovnoměrně rozloženy ve všech třídách, nebo jestli některá z tříd byla klasifikována lépe než jiná. Z tohoto důvodu byly zavedeny další ukazatele, kterými jsou tzv. uživatelská a zpracovatelská přesnost. Ty jsou počítány pro každou klasifikační třídu zvlášť. Uživatelská přesnost definuje pravděpodobnost, s jakou objekt skutečně reprezentuje třídu, do které je zařazen. Zpracovatelská přesnost představuje poměr počtu správně klasifikovaných objektů a celkového počtu objektů použitých pro testování dane třídy (Congalton, 1991).

Přesnost klasifikace lze také hodnotit pomocí tzv. Kappa koeficientu. Hodnota koeficientu porovnává klasifikaci s klasifikací vzniklou čistě náhodným zařazováním pixelů do tříd. Koeficient nabývá hodnot od 0 do 1 a například hodnota koeficientu 0,9 znamená, že v klasifikaci jsme se vyhnuli 90 % chyb, které by vznikly při klasifikaci náhodné. Pomocí Kappa koeficientu je možné například porovnávat chybové matice mezi sebou (Dobrovolný, 1998).

## 5 VÝSLEDKY

Cílem práce bylo vytvoření metodického postupu vhodného pro klasifikaci lesních porostů dle jejich poškození do předem zvoleného počtu tříd (5 klasifikačních tříd). K tomuto účelu byla použita multispektrální družicová data a data z leteckého laserového skenování. Zájmovým územím bylo povodí horní Vydry nacházející se v blízkosti obce Modrava v Národním parku Šumava u hranice s Německem.


Nejdříve bylo provedeno zpracování lidarových dat pro získání potřebné informace o výšce lesního porostu. Informace o výšce vegetace byla důležitá pro lepší rozlišení jednotlivých rozpadových či obnovujících se stádií lesa. Výsledný rastr nDSM získaný z těchto dat obsahující informaci o výšce vegetace je umístěn v Příloze 5. Následně byla provedena objektová klasifikace, která zahrnovala segmentaci obrazu a vytvoření klasifikační báze. Při klasifikaci byla kromě spektrálních informací využita také informace o výšce vegetace získaná z dat LLS. Jako vstupní hodnota do klasifikace byla zvolena průměrná výška vegetace v jednotlivých segmentech, která posloužila zejména k oddělení třídy 1 a 2 a také k rozdělení třídy 4 na další dvě kategorie. Výsledné klasifikační báze jsou umístěny v Příloze 7 a 8. Výsledky klasifikace byly z programu eCognition exportovány ve formátu shapefile a bylo provedeno hodnocení přesnosti výsledné klasifikace. Na závěr byla vytvořena mapa klasifikovaného lesa, která je umístěna v Příloze 9 a 10. Při tvorbě výsledných map nebyly prováděny žádné další postklasifikační úpravy.

### 5.1 Výsledky zpracování dat LLS a určení výšky vegetace


Jedním z úkolů práce byla konstrukce metodického postupu klasifikace lesa s využitím multispektrálních a lidarových dat. Lidarová data byla využita pro získání výškové informace o vegetaci. Zpracováním lidarových dat byl získán rastr nDSM s prostorovým rozlišením 2 m umístěný do souřadnicového systému UTM (zóna 33N) s referenčním elipsoidem WGS 84. Každý pixel tohoto rastru obsahuje informaci o výšce vegetace. Na obrázcích prezentovaný rastr zobrazuje v nejtmaších pixelech oblasti s nejnižší výškou a se světlejší barvou výška vegetace roste. Z výsledku (*Příloha 6*) je patrné, že nejnižší vegetace se nachází především v jižní části zájmového území, kde se vyskytují zjevně nejpoškozenější lesy této oblasti. Nejsvětější pixely s nejvyšší výškou vegetace se naopak nacházejí v místech zdravého a nepoškozeného lesa. Výsledný rastr nDSM byl v několika místech vizuálně porovnán s ortofotem a bylo zjištěno, že

ve většině zájmového území výška relativně přesně odpovídá místní situaci. Pro ukázkou je na obrázku 22 zobrazeno místo s poškozeným lesem na ortofotu i v rastru nDSM a na obrázku 23 oblast se zdravým lesem opět na obou vrstvách.

*Obr. 22 Ukázka poškozeného lesa na ortofotu a v rastru nDSM*



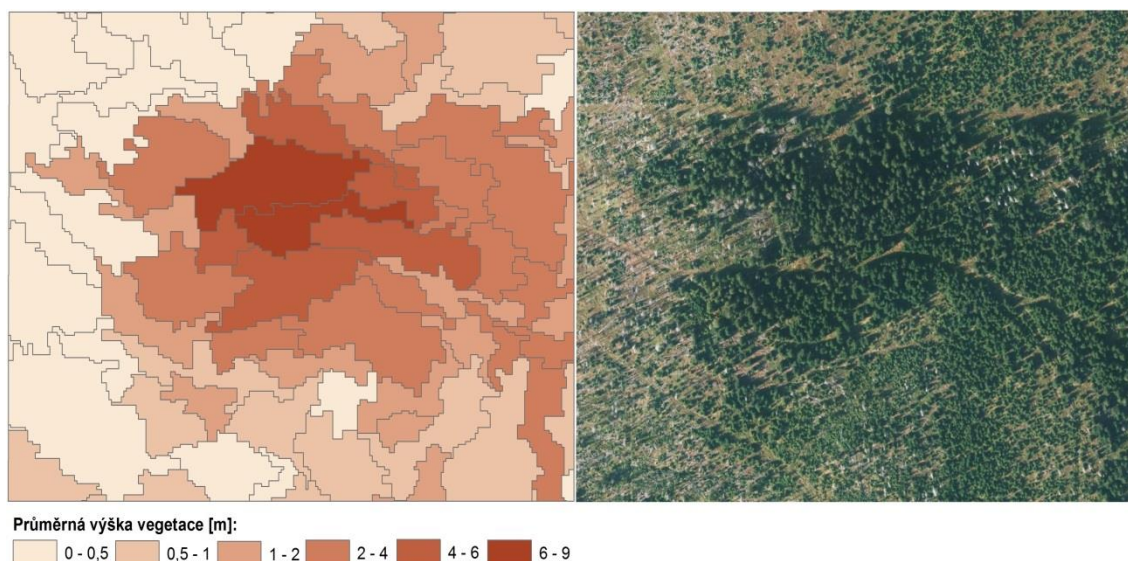
*Obr. 23: Ukázka zdravého lesa na ortofotu a v rastru nDSM*



Pro klasifikaci byly v programu eCognition z rastru nDSM vypočteny průměrné výšky vegetace za jednotlivé segmenty. Pro názornou ukázkou výsledných hodnot průměrných výšek za jednotlivé segmenty byl vytvořen kartogram, který je umístěný na obrázku 24. V levé části tohoto obrázku se nachází výřez zobrazující průměrné hodnoty výšky vegetace za jednotlivé segmenty a vpravo výřez z ortofota. V centrální části výřezu se dle ortofota nacházejí zdravé husté lesy a také v kartogramu průměrných výšek za jednotlivé segmenty se v této oblasti vyskytují nejvyšší hodnoty průměrné výšky. Naopak nejnižší hodnoty průměrné výšky za segment se nacházejí po levé straně výřezu, kde je z ortofota patrný výskyt poškozené a velmi řídké lesní vegetace. Při výpočtu průměrné výšky vegetace za segment hraje určitou roli také velikost tohoto segmentu. U menších segmentů se průměrná výška více blíží skutečné výšce vegetace, ale u segmentů s větší rozlohou může docházet ke shlazení výšky. Například v místech, kde se v takovémto segmentu nacházejí řídce rozmístěné stromy s určitou výškou,

budou do průměrné výšky započítány také odrazy od země a výsledná hodnota průměrné výšky za segment bude nižší, než je skutečná výška vegetace.

Obr. 24: Výřez průměrné výšky vegetace (vlevo) a ortofota (vpravo)



## 5.2 Výsledky objektové klasifikace

Objektově orientovaná klasifikace byla provedena v programu eCognition pouze nad maskou lesních oblastí. V prvním kroku byla provedena segmentace obrazu multiměřítkovou (*multiresolution*) metodou u které byla velká pozornost věnována nastavení parametrů. Celé zájmové území bylo pomocí segmentace rozděleno u snímku SPOT na celkem 23 239 segmentů o průměrné velikosti 3 631 m<sup>2</sup> a u snímku Landsat na 10 461 segmentů jejichž průměrná velikost byla 8 068 m<sup>2</sup>.

Následně bylo přistoupeno ke klasifikaci, při které byly jednotlivé segmenty zařazovány do předem definovaných klasifikačních tříd. Klasifikace byla provedena vytvořením klasifikační báze, v rámci které byly stanovovány prahové hodnoty jednotlivých příznaků. Kromě spektrálních vlastností byla pro klasifikaci využita také informace o výšce lesní vegetace, která byla získána z dat LLS. Vytvořená schémata klasifikační báze jsou zobrazeny v Přílohách 8 a 9. Vypočteny byly vegetační indexy RGI a NDVI. Všechny třídy byly v první fázi klasifikovány na základě prahových hodnot spektrálních charakteristik a průměrné výšky vegetace. Po aplikování těchto pravidel zbylo několik segmentů, které nebyly klasifikovány, protože nesplňovaly žádné z předchozích pravidel. Tyto objekty byly zařazeny do klasifikačních tříd na základě hodnot charakteristiky Relative border to.

Oba družicové snímky (zaostřený multispektrální snímek SPOT i multispektrální snímek Landsat) byli klasifikováni do celkem 5 tříd. Do první třídy, představující naprosto poškozené



lesy s téměř žádným vzrostlým vegetačním pokryvem, bylo zařazeno celkem 941 segmentů u snímku SPOT a 580 segmentů u snímku Landsat. Plocha této třídy činí u snímku SPOT 3,26 km<sup>2</sup>, což představuje 3,86 % z celkové rozlohy zájmového území. U snímku Landsat je to 4,15 km<sup>2</sup> tzn. 4,92 % z celkové plochy území. Jedná se o plošně nejméně zastoupenou třídu ve výsledné klasifikaci. Druhé třídě, představující rovněž poškozené lesy, avšak v segmentu se vyskytuje nižší či řidší vegetace, bylo přiřazeno k 3 336 segmentům u snímku SPOT a 2989 u snímku Landsat. Rozloha této třídy je 12,28 km<sup>2</sup> tedy 14,55 % z celkové rozlohy území u snímku SPOT a 20,47 km<sup>2</sup> u snímku Landsat. Lesy, ve kterých se mísí zdravé stromy s poškozenými, zastupuje třída 3. Ta byla klasifikována u 3 705 objektů s celkovou rozlohou 8,28 km<sup>2</sup> u snímku SPOT a u 3101 objektů s rozlohou 19,01 km<sup>2</sup> u snímku Landsat. Celkem 5 050 segmentů bylo klasifikováno jako třída 4a tedy zdravý les s nižší průměrnou výškou u snímku SPOT. V případě snímku Landsat bylo těchto objektů pouze 967. Nejpočetnější klasifikovanou třídou byla třída 4b, která zastupuje zdravý vzrostlý les. Do té bylo zařazeno celkem 10 207 segmentů s rozlohou 46,44 km<sup>2</sup> u snímku SPOT a 2824 segmentů pokrývajících 34,18 km<sup>2</sup> u snímku Landsat. Celkový přehled o počtu segmentů zařazených do jednotlivých tříd a o jejich rozloze je uveden v tabulkách 4 a 5.

Z níže uvedených tabulek je patrné, že u snímku SPOT jsou téměř tři čtvrtiny zájmového území pokryty zdravými lesy, ale u snímku Landsat tyto lesy pokrývají pouhou polovinu území. Tato kategorie se nachází především v severní polovině oblasti. Ve střední části území tato kategorie na mnoha místech přechází v částečně poškozené lesy (třída 3) a někde sousedí s již velmi poškozenou lesní vegetací (viz Příloha 10 a 11). Právě tyto oblasti, kde především vzrostlé zdravé lesy sousedí s lesy poškozenými, jsou velmi náchylné k dalšímu šíření poškození lesa. Zároveň je v těchto oblastech les náchylnější například k polomům při vichřicích, protože je většinou prořídlý a nechráněný. Nižší zastoupení zdravého lesa u snímku Landsat souvisí s datem pořízení snímku. Tato data byla pořízena o pět let později než SPOT a během tohoto období se území postižená kalamitou znatelně rozšířila.

*Tab. 4: Přehled výsledků objektově orientované klasifikace snímku SPOT*

<b>Třída</b>	<b>Počet segmentů</b>	<b>Rozloha [km<sup>2</sup>]</b>	<b>Podíl z celkové plochy [%]</b>
1	941	3,26	3,86
2	3 336	12,28	14,55
3	3 705	8,28	9,81
4a	5 050	14,13	16,74
4b	10 207	46,44	55,03
<b>Celkem</b>	23 239	84,39	100,00

Tab. 5: Přehled výsledků objektově orientované klasifikace snímku Landsat

Třída	Počet segmentů	Rozloha [km <sup>2</sup> ]	Podíl z celkové plochy [%]
1	580	4,15	4,92
2	2989	20,47	24,26
3	3101	19,01	22,53
4a	967	6,58	7,80
4b	2824	34,18	40,50
<b>Celkem</b>	10461	84,39	100,00

### 5.3 Výsledky hodnocení přesnosti klasifikace

Přesnost klasifikace byla hodnocena pomocí chybové matice za použití celkem 250 kontrolních bodů. Podle Lillesanda a Kiefera je pro každou třídu vhodné zvolit minimálně 50 bodů pro hodnocení přesnosti. Počet kontrolních bodů byl zvolen právě na základě tohoto pravidla. Pomocí chybové klasifikační matice byly výsledky klasifikace porovnány s referenčními daty. V tomto případě referenční data představovalo archivní ortofoto z roku 2005 pro SPOT a ortofoto z roku 2011 pro hodnocení přesnosti klasifikace snímku Landsat. Výsledné chybové matice jsou uvedeny v tabulkách 6 a 8. V tabulkách 7 a 9 jsou uvedeny uživatelské a zpracovatelské přesnosti spolu s přesností celkovou a kappa koeficientem.

Tab. 6: Chybová matice výsledné objektově klasifikace snímku SPOT

Referenční data							
Klasifikovaná data	třída	1	2	3	4a	4b	ř. celkem
	1	32	15	1	0	0	48
	2	18	34	7	0	0	59
	3	0	1	38	1	0	40
	4a	0	0	4	37	4	45
	4b	0	0	0	12	46	58
	sl. celkem	50	50	50	50	50	250

U snímku SPOT bylo z celkem 250 objektů 187 klasifikováno správně. Z 50 objektů představujících v referenčních datech třídu 1 jich bylo správně klasifikováno 32 a zbylých 18 bylo klasifikováno jako třída 2. Příčinou může být to, že na základě spektrální informace se tyto dvě třídy jevily velmi podobně. Rozlišeny byly pouze na základě výškové informace, která byla pořízena o 5 let později. Stejně tomu bylo i u třídy 2, která byla v 34 případech klasifikována správně a v 15 byla zaměněna s třídou 1. Opět může být příčinou později pořízená výšková informace. Plochy, které v roce 2005 představovaly poškozené lesy se stojícími suchými stromy, mohly během 5 let zmizet a jejich průměrná výška se snížila. Proto mohly být nesprávně klasifikovány do třídy 1. U zdravých lesů s nižším věkem bylo správně klasifikováno 37 objektů a nesprávně zařazené objekty byly nejčastěji chybně klasifikovány

jako vzrostlý zdravý les. Příčinu lze opět hledat v časovém rozestupu pořízení LLS dat. V době pořízení ortofota v roce 2005 tyto lesy mohly být nízké, ale během pěti let vzrostly a na základě LLS dat tak byly klasifikovány jako třída 4b. Nejlépe v chybové matici dopadla třída zdravých vzrostlých lesů 4b, kde bylo správně zařazeno celkem 46 objektů.

*Tab. 7: Uživatelská, zpracovatelská, celková přesnost a kappa koeficient (SPOT)*

<b>Třída</b>	<b>Zpracovatelská přesnost [%]</b>	<b>Uživatelská přesnost [%]</b>	<b>Kappa koeficient [%]</b>
1	64,00	66,67	58,33
2	68,00	57,63	47,03
3	76,00	95,00	93,75
4a	74,00	82,22	77,78
4b	92,00	79,31	74,14
<b>Celkový kappa koeficient (overall kappa) [%]</b>			<b>68,50</b>
<b>Celková přesnost (overall accuracy) [%]</b>			<b>74,80</b>

Celková přesnost klasifikace snímku SPOT činí 74,8 % na základě ukazatele overall accuracy a 68,5 % podle kappa koeficientu. Tyto hodnoty lze považovat za průměrné.

Nejvyšší přesnost klasifikace podle kappa koeficientu vykazuje třída 3, která představuje les se zdravými i poškozenými stromy. Uživatelská přesnost této třídy je dokonce 95 %. Ze 40 ploch, které byly klasifikovány jako tato třída, byly pouze 2 zařazeny špatně. Zpracovatelská přesnost třídy 3 je 76 %, přičemž nejvíce špatně zařazených ploch spadlo do třídy 2, která představuje poškozené lesy se stojícími mrtvými stromy.

Nejhorších výsledků podle kappa koeficientu naopak dosáhla třída 2, která má nejnížší hodnotu uživatelské přesnosti a druhou nejnížší hodnotu u přesnosti zpracovatelské. Z 50 referenčních ploch bylo 34 klasifikováno správně, což dává zpracovatelskou přesnost 68 %. Ještě nižší hodnotu dosáhla tato třída u uživatelské přesnosti, která činí pouze 57,63 %. Tuto hodnotu způsobilo především 18 špatně klasifikovaných objektů z třídy 1.

Jen o málo lepších výsledků dosáhla při klasifikaci třída 1. Její zpracovatelská přesnost je ještě nižší než u třídy 2. Z 50 referenčních ploch jich bylo 32 klasifikováno správně. Uživatelská přesnost je se svými 66,67 % o něco vyšší než u nejhůře klasifikované třídy.

Lepších výsledků dosáhly kategorie 4a a 4b, které představují zdravé lesy rozlišené podle výšky na vzrůstající a již vzrostlé. Zpracovatelská přesnost je vyšší u třídy 4b, a to konkrétně 92 %. Z 50 referenčních objektů jich bylo 46 klasifikováno správně. Třída 4a má zase vyšší uživatelskou přesnost, jejíž hodnota je 82,22 %. Tato hodnota říká, že ze 45 objektů klasifikovaných jako třída 4a jich bylo 37 klasifikováno správně.

Tab. 8: Chybová matice výsledné objektové klasifikace snímku Landsat

Referenční data							
Klasifikovaná data	třída	1	2	3	4a	4b	ř. celkem
	1	33	2	0	0	0	35
	2	14	41	5	6	1	67
	3	3	6	37	2	1	49
	4a	0	0	2	34	0	36
	4b	0	1	6	8	48	63
	sl. celkem	50	50	50	50	50	250

U snímku Landsat bylo celkem z 250 objektů 193 klasifikováno správně. Z 50 objektů představujících v referenčních datech třídu 1 jich bylo správně klasifikováno 33. Dalších 14 bylo klasifikováno jako třída 2 a 3 jako třída 3. Podobná situace byla i u třídy 2, která byla správně klasifikována v 41 případech. Kromě chyby v metodě klasifikace příčinou může být i roční rozestup mezi referenčním ortofotem a snímkem Landsat. Plochy, které se na ortofotu v roce 2011 jeví jako třída 1, mohly být ještě před rokem, při pořízení družicových a lidarových dat, představovat třídu 2. Tyto oblasti mohly být odtěženy nebo došlo k popadání stromů, a proto může docházet k jejich záměně. U zdravých lesů s nižším vzrůstem bylo správně klasifikováno 34 objektů a nesprávně zařazené objekty byly nejčastěji chybně klasifikovány jako vzrostlý zdravý les. Nejlépe v chybové matici dopadla třída zdravých vzrostlých lesů 4b stejně tak jako u snímku SPOT. V té bylo správně zařazeno celkem 48 objektů.

Tab. 9: Uživatelská, zpracovatelská, celková přesnost a kappa koeficient (Landsat)

Třída	Zpracovatelská přesnost [%]	Uživatelská přesnost [%]	Kappa koeficient [%]
1	66,00	94,29	92,86
2	82,00	61,19	51,49
3	74,00	75,51	69,39
4a	68,00	94,44	93,06
4b	96,00	76,19	70,76
<b>Celkový kappa koeficient (overall kappa) [%]</b>			<b>72,30</b>
<b>Celková přesnost (overall accuracy) [%]</b>			<b>77,20</b>

Celková přesnost klasifikace snímku Landsat činí 77,2 % na základě ukazatele overall accuracy a 72,3 % podle kappa koeficientu. Tyto hodnoty jsou o něco vyšší než v případě předchozí klasifikace snímku SPOT. Důvodem pravděpodobně bude to, že data LLS a Landsat byla pořízena ve stejném roce na rozdíl od dat SPOT.

Nejvyšší přesnost klasifikace na základě kappa koeficientu vykazuje třída 4a, která představuje nižší zdravý les v růstu a třída 1. Uživatelská přesnost třídy 4a je dokonce 94,44 % a u třídy 1 je tato hodnota 94,29 %. Z 36 ploch, které byly klasifikovány jako třída 4a byly pouze 2 zařazeny špatně. U třídy 1 to bylo z 35 ploch opět pouze 2 špatně zařazené. Zpracovatelská

přesnost třídy 4a je 68 %, přičemž nejvíce špatně zařazených ploch spadlo do třídy 4b, která představuje již vzrostlé zdravé lesy. U třídy 1 dosáhla tato přesnost hodnoty 66 % a nejvíce špatně zařazených ploch spadlo do třídy 2.

Nejhorších výsledků podle kappa koeficientu naopak dosáhla třída 2, která má nejnižší hodnotu uživatelské přesnosti. Tato třída dopadla nejhůře i při klasifikaci snímku SPOT. V této třídě lze spatřit patrně největší slabinu zvolené metodiky. Z 50 referenčních ploch bylo 41 klasifikováno správně, což dává zpracovatelskou přesnost 82 %. Ještě nižší hodnotu dosáhla tato třída u uživatelské přesnosti, která činí pouze 61,19 %. Tuto hodnotu způsobilo především 14 špatně klasifikovaných objektů z třídy 1.

Podobných výsledků podle kappa koeficientu dosáhla klasifikace u třídy 3 a 4b. Zpracovatelská přesnost třídy 4b dosáhla dokonce hodnoty 96 %. Z 50 referenčních objektů jich bylo 48 klasifikováno správně.


## 6 DISKUZE

Data dálkového průzkumu Země jsou pro klasifikaci lesa a určení jeho zdravotního stavu využívána již mnoho let. I v dnešní době je toto téma stále aktuální vzhledem k neustále se vyskytujícímu lesnímu poškození vlivem četných kalamitních událostí. Na základě výsledků této diplomové práce lze říci, že použití multispektrálních družicových snímků v kombinaci s informací z lidarových dat má v této oblasti poměrně vysoký potenciál. Tento přístup lze využít například pro určení poškození lesa, jehož příčinou může být přemnožení lýkožrouta smrkového, vichřice nebo jakákoli jiná událost. To, že družicová data jsou velmi vhodná pro klasifikaci lesa na základě jeho zdravotního stavu, potvrzují mnohé práce. Kombinace těchto dat s daty lidarovými za účelem hodnocení poškození lesa se však neobjevila téměř v žádné pročené odborné literatuře. Mnoho autorů se soustředí na zjištění strukturních parametrů lesa pouze za použití dat LLS (např. Lim et al., 2003 nebo Hyypä, 2001). K tomuto účelu je však potřeba mít k dispozici data LLS s vysokou hustotou bodů, která jsou velmi finančně náročná. Pro potřeby této diplomové práce byla však k dispozici pouze lidarová data s nízkou hustotou bodů, proto byla zvolena kombinace s daty družicovými. Podle Solberga (2006) představuje právě kombinace multispektrálních dat s daty leteckého laserového skenování slibný nástroj pro hodnocení zdravotního stavu lesa.

Při hodnocení přesnosti klasifikace se jako důležité ukázalo datum pořízení dat, které by u obou typů mělo být co možná nejbližší. V tomto případě byl mezi pořízením družicových dat SPOT a dat z leteckého laserového skenování časový rozestup 5 let, který se negativně projevil na výsledcích klasifikace. V některých případech se na družicovém snímku SPOT les jevil jako zdravý, ale jeho průměrná výška byla velmi nízká. Příčinu tohoto nesouladu je možné určit právě v časovém rozdílu pořízení multispektrálních a LLS dat. V této souvislosti však musí být uvedeno, že se práce snažila nalézt metodický postup pokud možno co nejpřesnějšího určení zdravotního stavu lesní vegetace pomocí kombinace multispektrálních a lidarových dat. V tomto ohledu má využití družicových dat velmi vysokého prostorového rozlišení velké perspektivy i s ohledem na plánované mise Sentinel, které budou produkovat volně dostupná multispektrální data. Pro posouzení vhodnosti vytvořené metodiky bylo rozhodnuto použít také data Landsat, která byla nasnímána ve stejném roce jako data lidarová. Ačkoliv se velikost pixelu zvětšila díky použití těchto dat, což mělo vliv na segmentaci obrazu, zpracování přineslo relevantnější výsledky díky totožnému roku pořízení s daty lidarovými.


Zmiňovaný negativní vliv různého roku pořízení snímku SPOT (2005) a dat LLS (2010) je demonstrován pro ukázkou na následujících obrázcích, kde je použito ortofoto ze stejného roku jako snímek SPOT. Průměrná výška za jednotlivé segmenty byla počítána z rastru nDSM, který byl vytvořen z dat LLS. Před použitím tohoto rastru pro klasifikaci byl v několika místech vizuálně porovnán s ortofotem. Zjištěno bylo, že ve většině území výška v rastru nDSM relativně odpovídá místní situaci na ortofotu. Bylo však nalezeno také několik míst, kde výška vegetace příliš nekorespondovala se stavem zjištěným podle ortofota. Například na obrázku 25 je patrné, že podle ortofota by v této oblasti měl být zdravý les pouze s malou oblastí poškozené lesní vegetace. Na rastru nDSM však stejná oblast působí dojmem, že se v ní nachází poškozeného lesa o něco více. Tyto rozdíly mohou být s velkou pravděpodobností způsobené časovým rozestupem (5 let), který je mezi oběma typy dat. Časový rozestup mezi daty je způsoben tím, že se nepodařilo sehnat data LLS ke stejnému roku jako snímek SPOT, který byl získán dříve. Právě tento fakt může být příčinou rozdílů v některých oblastech. Na snímku se může v těchto místech les jevit jako zdravý, ale v době pořízení dat LLS již může být poškození rozšířeno i do této oblasti. Situace však může být i opačná. Oblast na snímku může působit jako poškozený les, ale během pěti let může být zalesněný novými a zdravými stromy. Při vizuálním porovnání ortofota s rastrem nDSM však takovýchto oblastí nebylo nalezeno mnoho. Do budoucna by však bylo samozřejmě lepší použít data s minimálním časovým rozdílem. Z tohoto důvodu byl pro klasifikaci použit také snímek Landsat, který se časově s daty LLS shoduje. Na obrázku 26 je znázorněna stejná oblast jako na předchozím, ale je porovnána s ortofotem z roku 2011, které je k dispozici na portálu ČÚZK a nejvíce se blíží roku pořízení snímku Landsat. Z něj je patrné, že s rastrem nDSM koresponduje již o něco lépe, a to zejména z důvodu pouze ročního odstupu při pořízení obou typů dat.

*Obr. 25: Ukázka oblasti působící rozdílně na ortofotu z roku 2005 a v rastru nDSM*





*Obr. 26: Ukázka stejné oblasti na ortofotu z roku 2011 a v rastru nDSM*



Důležitým cílem této diplomové práce byla také tvorba klasifikačního systému, který by rozlišil potřebný počet tříd pro určení rozpadových či obnovujících se stádií lesa. Na tomto místě je důležité zmínit, že existuje celá řada studií, které se zaměřují na tuto problematiku i ve spojení s mapováním kůrovcem poškozených lesů. Většina z nich je však omezena pouze na jeden druh dat (buď letecká, nebo družicová). Díky tomuto faktu jsou lesy na základě jejich zdravotního stavu zařazovány většinou pouze do dvou maximálně tří klasifikačních tříd. Například Hájek a Svoboda (2007) rozlišovali následující dvě třídy lesa: (1) živý les a (2) suchý les. Do kategorie živý les byly zařazeny stromy, které v době pořízení leteckého snímku měly převážnou část asimilačních orgánů v zelené barvě. Do kategorie suchý les byly zařazeny stromy, u kterých v době pořízení leteckého snímku asimilační orgány ztratily zelenou barvu a stromy bez asimilačních orgánů s korunou tvořenou suchými větvemi v různém stádiu rozpadu koruny. K rozlišení těchto tříd použily barevné a IČ letecké snímky. Meddens, Jeffrey a Vierling (2011) rozlišili na základě leteckých snímků o jednu třídu více. V jejich studii jsou lesy klasifikovány do tříd zdravé lesy, poškozené lesy s červenými jehlicemi a poškozené lesy bez jehlic. Nejčastěji jsou pro hodnocení zdravotního stavu lesa používány snímky Landsat na základě kterých je ovšem rozlišováno také menší počet tříd. Medens et al. (2013) pomocí těchto snímků rozlišil 2 třídy, a to nepoškozené lesy a poškozené lesy ve fázi red-attack. Nejmodernější je ovšem použití družicových dat s velmi vysokým prostorovým rozlišením. Tato data použil např. Coops et al. (2006), ale rozlišil na základě nich opět pouze poškozený a nepoškozený les. Stejně třídy na základě dat QuickBird rozlišili také Hicke a Logan (2009). O jednu třídu víc rozlišili Dennison, Brunelle a Carter (2010), kteří na základě snímku GeoEye-1 rozlišili zdravé lesy, poškozené lesy ve fázi red-attack a poškozené lesy ve fázi grey-attack. V ČR se standardně používá metodika pro sledování poškození a mortality lesních porostů, která je vytvářena Ústavem pro hospodářskou úpravu lesů (ÚHUL). K tvorbě těchto map jsou používány multispektrální družicové snímky



Landsat TM/ETM+. Lesní porosty jsou podle této metodiky klasifikovány do 6 tříd: (1): porosty zdravé, (2) s prvními příznaky poškození, (3) s mírným poškozením, (4) se středním poškozením, (5) porosty silně poškozené a (6) velmi silně poškozené. Metodika, která se k tomuto účelu používá, však není nikde zveřejněna. Zvolená metodika byla inspirována výše uvedenými studiemi a dala si za cíl rozlišit pokud možno co nejvíce tříd lesa pomocí kombinace multispektrálních a lidarových dat.

V první fázi bylo použito zaostřeného multispektrálního snímku SPOT a informace o průměrné výšce porostu, která byla získána z dat LLS. Rozlišeno bylo celkem 5 klasifikačních tříd lesa podle stupně jejich poškození: (1) třída 1 – poškozené lesy se stojícími řídce rozmístěnými pahýly suchých stromů, s popadanými uschlými stromy nebo se stromy odtěženými, (2) třída 2 – poškozené lesy se stojícími uschlými stromy, (3) třída 3 – oblasti, ve kterých jsou smíchány zdravé stromy s poškozenými uschlými stromy, (4) třída 4a – zdravé lesy ve vzrůstu, které se obnovují a (5) třída 4b – vysoké zdravé lesy.

Takto vytvořené klasifikační schéma by mělo být použitelné v dalších vědních oblastech, jako například v hydrologii, lesním managementu nebo ochraně přírody a krajiny. V hydrologii mohou tyto informace posloužit například při hodnocení lokálních odtokových poměrů. Výsledky klasifikace jsou užitečné i pro instituce ochrany přírody, které by díky němu mohly zhodnotit stav poškození lesa a určit nejvíce ohrožené oblasti.

Kromě vhodného typu vstupních dat a počtu klasifikovaných tříd práce v neposlední řadě řešila samotné zpracování dat. Podíváme-li se do relevantní odborné literatury, tak stále nejčastěji používanou metodou je pixelová klasifikace, kterou použili např. Meddens, Jeffrey a Vierling (2011), DeRose, Long a Ramsey (2011) nebo Hicke a Logan (2009). Nevýhodou pixelové klasifikace je tzv. salt and pepper effect neboli vznik osamocených pixelů. Tento typ klasifikace nebyl použit zejména z tohoto důvodu a také proto, že při něm nelze použít zároveň spektrální vlastnosti vegetace a informaci o výšce. Podle Hájka a Svobody (2007) je analýza obrazu úspěšnější při použití objektově orientované klasifikace, při které lze právě využít kromě spektrálních i jiné charakteristiky. Metodu objektové klasifikace použil také Morales, Miura, Idol (2008), kteří se ve své studii zabývali hodnocením suchého lesa s využitím snímků s velmi vysokým prostorovým rozlišením. Ouyanga et al. (2011) tuto metodu doporučuje zejména při práci s VHR daty. Pro klasifikaci lesního porostu byla v této práci zvolena metoda objektově orientované klasifikace. Hlavním důvodem bylo to, že bylo nutné do klasifikace začlenit také informaci o výšce vegetace, která byla získána v podobě rastru z LLS dat. Jako charakteristiky byly použity také vegetační indexy RGI a NDVI, které jsou podle mnoha autorů vhodně pro odlišení poškozeného lesa (např. Solberg et al., 2007, Coops et al., 2006 nebo Hicke a Logan, 2009).

Prvním nutným krokem objektově orientované klasifikace byla volba metody segmentace obrazu. Té je podle některých autorů (př. Meinel, Neubert, 2004) potřeba věnovat velkou


pozornost, a to zejména při volbě nastavitelných parametrů. Kvalita segmentace totiž výrazně ovlivňuje kvalitu výsledné klasifikace. Pro zpracování obrazových dat v této práci byla použita metoda s názvem Multiresolution segmentation (multiměřítková segmentace), která podle Meinela a Neuberta (2002) podává nejlepší výsledky. Tento typ segmentace je využíván v drtivé většině studií, ve kterých je segmentace obrazu prováděna. Při objektově orientované klasifikaci ji použil například Hájek a Svoboda (2007) nebo Wulder (2008). Vyzkoušeno bylo několik hodnot všech parametrů a na základě vizuálního zhodnocení byly vybrány ty nejvhodnější. Jako nejvhodnější volba pro segmentaci snímku SPOT s rozlišením 2,5 m byla zvolena kombinace parametrů: měřítkový parametr 30, barva 0,7, tvar 0,3, kompaktnost 0,4 a hladkost 0,6. Při segmentaci snímku Landsat s prostorovým rozlišením 30 m byla zvolena kombinace parametrů: měřítkový parametr 35, barva 0,8, tvar 0,2, kompaktnost 0,3 a hladkost 0,7. Při segmentaci vznikly objekty, které svojí velikostí nezachytí jednotlivé stromy, ale jsou vhodné pro klasifikaci lesa na úrovni porostů, tzn. vymezí porosty s podobnými vlastnostmi. Tato informace je klíčová pro lesní management, který pro svá rozhodnutí potřebuje znát podobně určená společenstva. Po segmentaci obrazu byla vytvořena klasifikační báze, při které byly stanoveny prahové hodnoty jednotlivých vstupních příznaků. Jako hlavní příznaky byly využity u snímku SPOT hodnoty indexu RGI a hodnoty průměrné výšky vegetace za segment. Index RGI dle mého názoru dokázal vystihnout jednotlivé třídy lépe než druhý vegetační index NDVI, který byl také vyzkoušen. Po aplikaci stanovených pravidel zbylo několik segmentů, pro jejichž klasifikaci byla využita charakteristika *Relative border to* a pro závěrečné zařazení zbylých neklasifikovaných objektů byl využit index NDVI. Alternativou tohoto zařazování neklasifikovaných segmentů by bylo, ponechat je jako neklasifikované nebo pro ně vytvořit další třídu "ostatní". Právě tato část metodiky je tou, na které by se mohlo dále pracovat. U snímku Landsat se jako nejvhodnější jevíly pro klasifikaci hodnoty indexu RGI, hodnoty v pásmu NIR a opět hodnoty průměrné výšky vegetace. Hodnoty v pásmu NIR byly využity pro vymezení třídy 1 a 2, které index RGI nevymezil nejlépe. Opět byla použita také charakteristika *Relative border to* a pro závěrečné zařazení neklasifikovaných objektů bylo využito pásmo Greenness z transformace Tasseled Cap. Všechny použité prahové hodnoty a přehled kompletní klasifikace je umístěn v přílohách 8 a 9 a také v digitální podobě na disku CD.

Snímky SPOT i Landsat byly klasifikovány do 5 výše zmíněných tříd, přičemž na základě výsledků klasifikace lze říci, že nejvíce poškozené lesy se nacházejí v jižní části zájmového území. Plocha nejvíce poškozených lesů (třída 1 a 2) představuje necelých 20 % z celkové plochy řešené oblasti v případě klasifikace snímku SPOT a téměř 30 % v případě klasifikace snímku Landsat. V největší míře jsou zastoupeny lesy zdravé, které na snímku SPOT pokrývají téměř 72 % plochy zájmového území. Ze snímku Landsat jich však bylo detekováno méně: cca 50 %. Hlavní příčinu těchto rozdílů možno spatřit zejména v časovém posunu pořízení obou družicových snímků. Na zdravé lesy detekované ze snímku SPOT mohlo být během 5 let rozšířeno poškození, tudíž může být množství zdravých lesů na snímku Landsat nižší.

Přesnost klasifikace ovlivňuje hned několika faktorů, mezi které lze zařadit samotné družicové multispektrální snímky SPOT a Landsat, použitá data LLS a způsob jejich zpracování, metoda klasifikace i zvolené prahové hodnoty. Přesnost klasifikace byla hodnocena na podkladě ortofot z roku 2005 a 2011 jako referenčních dat za použití chybové matice a kappa koeficientu. V neposlední řadě výslednou přesnost ovlivnil také fakt, že třída, do které body použité pro hodnocení přesnosti patří v realitě, byla určována pouze na základě vizuálního posouzení z ortofota. Je nutné připustit, že i při tomto zařazení mohlo dojít k chybám, a to především u třídy 2 a 4a. Tyto dvě třídy nelze pouze z ortofota stoprocentně rozpoznat, a to z toho důvodu, že k jejich odlišení byla využita výšková informace. Zejména body pro třídu 4a byly vybírány v místech, kde bylo skutečně patrné, že stromy jsou zde nízké a i jejich barva je světlejší. Naopak do třídy 2 byly body v ortofotu vybrány v místech, kde se nachází hustěji rozmístěné pahýly stromů, které jsou na ortofotu rozpoznatelné zejména podle stínů, které se pod nimi nacházejí. Tento způsob zařazování bodů do tříd nad ortofotem byl zvolen z toho důvodu, že nebylo možné provést terénní průzkum, a to vzhledem k tomu, že snímek SPOT byl 8 let starý a snímek Landsat 3 roky starý. Do budoucna by však, v případech kdy to bude možné, bylo pro hodnocení přesnosti vhodnější využít data z terénního šetření.

Přesnost klasifikace jistě ovlivnily také zvolené charakteristiky a jejich prahové hodnoty, které byly pro klasifikaci použity. Na základě trénovacích ploch pro každou třídu byl vytvořen jakýsi přehled o hodnotách jednotlivých charakteristik. Dle toho byly vybrány ty nejvhodnější charakteristiky a podle vizuálního porovnání s ortofotem zvoleny výsledné prahové hodnoty. Z výsledků hodnocení přesnosti klasifikace se ukazuje, že za největší slabinu klasifikace lze považovat třídu 2, která dosáhla nejnižších hodnot přesnosti u obou klasifikací, což ukazuje také níže uvedený graf (*graf 1*). Důvodem může být jak špatná klasifikace těchto segmentů, tak například špatné zařazení těchto bodů do třídy na základě ortofota. Na tomto místě je vhodné připustit, že použití například jiných vegetačních indexů nebo jiných prahových hodnot by mohlo zlepšit výsledky klasifikace.

*Graf 1: Přesnost jednotlivých tříd při klasifikaci snímků SPOT a Landsat*



Celková přesnost klasifikace dosáhla u snímku SPOT 78,4 % na základě ukazatele overall accuracy a 68,5 % podle kappa koeficientu. Tyto hodnoty lze považovat za průměrné. U snímku Landsat byla zjištěná přesnost o něco vyšší, a to konkrétně 77,2 % na základě ukazatele overall accuracy a 72,3 % podle kappa koeficientu. Hájek a Svoboda (2007) dosáhli pomocí objektové klasifikace lesa hodnoty kappa koeficientu v rozmezí 85 – 93 %. Ve své studii však les rozdělili jen do dvou tříd. Hicke a Logan (2009) klasifikovali snímek QuickBird za účelem zmapování lesů poškozených kůrovcem v centrálním Idahu v USA. Při klasifikaci dosáhli celkové přesnosti (*overall accuracy*) 86 % a hodnoty kappa koeficientu 82 %. Avšak i oni klasifikovali les pouze do dvou tříd. Meddens, Jeffrey a Vierling (2011) klasifikovali les do 3 tříd za použití multispektrálních leteckých snímků s prostorovým rozlišením 2,4 m. Ve své práci dosáhli celkové přesnosti 90 % a kappa koeficientu 88 %. Celkově lze tedy říci, že přesnosti klasifikace v této práci byla o něco nižší než u ostatních odborných studií. Počet klasifikačních tříd lesa byl však v porovnání se všemi odbornými články vyšší, což určitě výrazně ovlivnilo výsledky hodnocení.

## 7 ZÁVĚR

Hlavním cílem předložené diplomové práce byla tvorba metodického postupu vhodného pro hodnocení míry poškození lesních porostů ve vybrané oblasti NP Šumava při kombinaci multispektrálních a lidarových dat. Na základě tohoto metodického postupu by měl být rozlišen požadovaný počet klasifikačních tříd, které rozliší jednotlivá rozpadová stadia lesů či jejich obnovu. Dílčími úkoly bylo zpracování přehledu o současném pokroku v metodách využívaných pro detailní klasifikaci lesa pomocí dat DPZ, zpracování a využití LLS dat a zhodnocení výsledné přesnosti. Práce se proto v první části věnuje rešerši odborné literatury a podává přehled jak o využití DPZ v lesnictví obecně, tak o metodách DPZ využívaných pro zjišťování zdravotního stavu lesa napadeného kůrovcem. V této části jsou také stručně popsány obecné vlastnosti družicových a lidarových dat. Prostor je věnován také popisu hlavních přístupů objektově orientované klasifikace, která byla v práci využita. Hlavní část diplomové práce se věnuje zpracování lidarových dat v software E3De (Envi Lidar) a sestavení klasifikační báze v programu eCognition s využitím družicových snímků SPOT, Landsat a dat LLS. Objektová klasifikace byla provedena ve dvou krocích. Nejprve byla provedena segmentace obrazu metodou multiměřítkové segmentace, při které byly nalezeny vhodné parametry pro oba klasifikované snímky. Následně byl obraz klasifikován do 5 předem definovaných klasifikačních tříd na základě vlastních vytvořených pravidel a určených prahových hodnot jednotlivých charakteristik. Bylo zjištěno, že při kombinaci několika typů dat je velmi důležité, aby časový rozestup mezi daty byl minimální. Toto se projevilo jako problematický faktor při klasifikaci snímku SPOT, kdy časový rozestup mezi pořízením tohoto snímku a daty z leteckého laserového skenování byl 5 let. Tento fakt se projevil ve výsledcích klasifikace. Pro účely časového souladu pořízení LLS dat a multispektrálních dat byl klasifikován snímek Landsat, jehož datum pořízení se s LLS daty téměř shoduje. Předpoklad, že kombinací multispektrálních a lidarových dat bude možné rozlišit vyšší počet tříd než v prostudované literatuře, byl potvrzen. Dle zjištěných poznatků z literatury lze tvrdit, že za použití pouze multispektrálních dat je možné klasifikovat les pouze do limitovaného počtu tříd (max. 3 třídy), kdežto přidáním informace o průměrné výšce získané z lidarových dat se mohl počet tříd významně rozšířit (5 tříd). Pro účely této práce definované třídy 1 a 2 by pouze z multispektrálních dat nebylo možné rozlišit a stejně tak třídy 4a a 4b. Další hypotézou bylo, že u klasifikace snímku Landsat bude dosaženo vyšší přesnosti klasifikace z důvodu již zmíněného shodného data pořízení s LLS daty. Tento předpoklad byl rovněž potvrzen. Přesnost klasifikace

snímku Landsat byla vyšší než v případě použití snímku SPOT, a to o necelých 5 % u hodnoty kappa koeficientu a o necelá 3 % u hodnoty overall accuracy.

Závěrem lze tedy říci, že se v práci podařilo navrhnout a otestovat metodický postup klasifikace lesních porostů do 5 zvolených tříd stupně poškození. Přesnost navržené metody založené na objektově orientované klasifikaci multispektrálního družicového snímku doplněného o výškovou informaci z rastru nDSM byla zhodnocena na podkladě ortofota. Při srovnání s jinými podobně orientovanými studiemi možno konstatovat, že dosaženou přesnost možno zhodnotit jako průměrnou. Na tomto místě se ovšem nesmí opomenout fakt, že námi zvolený přístup měl za úkol rozlišit více tříd než doposud řešila většina studií zaměřených na hodnocení zdravotního stavu lesů pomocí multispektrálních snímků. Potvrdilo se, že kombinace LLS dat s družicovými multispektrálními daty představuje významný potenciál pro hodnocení zdravotního stavu lesních porostů a tuto kombinaci dat lze doporučit pro využití a následný detailnější výzkum. Do budoucna by mohla být pro kombinaci s multispektrálními daty použita například lidarová data s vyšší hustotou bodového mračka. Uplatnit by se mohly také další informace, které by bylo z těchto dat možné získat, jako například objem biomasy, hustota vegetace nebo zápoj a další.

## SEZNAM POUŽITÝCH ZDROJŮ INFORMACÍ

ARCDATA PRAHA (2012): *Družicová data distribuovaná společností ARCDATA PRAHA, s.r.o.* [online]. Arcdata Praha, s.r.o. 2013 [cit. 2013-02-21]. Dostupné z URL: <<http://www.arcdata.cz/produkty-a-sluzby/geograficka-data/druzicova-data/>>.

BAATZ, M.; SCHÄPE, A. 2000. *Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation* [online]. 2000 [cit. 2011-1-7]. Dostupné z URL: <[http://www.ecognition.cc/download/baatz\\_schaepe.pdf](http://www.ecognition.cc/download/baatz_schaepe.pdf)>.

CONGALTON, R. G. (1991): A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data [online]. Remote Sensing of Environment. 1991, č. 37, s. 35-46 [cit. 2013-02-21]. Dostupné z URL: <<http://www.srn.arizona.edu/rnr/rnr419/publications/Congalton1991.pdf>>.

COOPS, N. C. ...[et al.] (2006): *Assessment of QuickBird high spatial resolution imagery to detect red attack damage due to mountain pine beetle infestation* [online]. Remote Sensing of Environment. 2006, č. 103, s. 67-80 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425706001283>>.

DALPONTE, M.; BRUZZONE, L.; GIANELLE, D. (2012): *Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data* [online]. Remote Sensing of Environment. 2009, č. 113, s. 1540-1555 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425712001320>>.

DENNISON, P. E.; BRUNELLE, A. R.; CARTER, V. A. (2010): *Assessing canopy mortality during a mountain pine beetle outbreak using GeoEye-1 high spatial resolution satellite data* [online]. Remote Sensing of Environment. 2010, č. 114, s. 2431-2435 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425710001653>>.

DEROSE, R. J.; LONG, J. N.; RAMSEY, R. D. (2011): *Combining dendrochronological data and the disturbance index to assess Engelmann spruce mortality caused by a spruce beetle outbreak in southern Utah, USA* [online]. Remote Sensing of Environment. 2005, č. 94, s. 364-372 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S003442571001623>>.

DOBROVOLNÝ, P. (1998): *Dálkový průzkum Země: digitální zpracování obrazu*. 1. vyd. Brno: Masarykova univerzita, 1998. 208 s. ISBN: 80-210-1812-7.

DOLANSKÝ, T. (2004): *Lidary a letecké laserové skenování*. Ústí nad Labem: Univerzita J. E. Purkyně, 2004. 100 s. ISBN 80-7044-575-0.

FÜHRER, E. (2000): *Forest functions, ecosystem stability and management* [online]. Forest Ecology and Management. 2000, č. 132, s. 29-38 [cit. 2013-03-10]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0378112700003777>>.

Gisat (200-?): *Družicová data* [online]. 200-? [cit. 2013-02-22]. Dostupné z URL: <<http://www.gisat.cz/content/cz/druzicova-data>>.

Gisat (200-?): *Klasifikace* [online]. 200-? [cit. 2013-02-22]. Dostupné z URL: <<http://www.gisat.cz/content/cz/dpz/zpracovani-dat/klasifikace>>.

Geodis (200-?): *Letecké laserové skenování – LIDAR* [online]. 200-? [cit. 2013-02-22]. Dostupné z URL: <<http://sluzby.geodis.cz/sluzby/letecky-laserscanning>>.

HAIS, M. (2009): *Využití dálkového průzkumu Země pro monitoring lesů na Šumavě* [online]. Životní prostředí. 2009, roč. 43, č. 4, s. 216-219 [cit. 2013-02-21]. Dostupné z URL: <<http://www.npsumava.cz/storage/str49-55.pdf>>.

HAIS, M. ...[et al.] (2009): *Comparison of two types of forest disturbance using multitemporal Landsat TM/ETM+ imagery and field vegetation data* [online]. Remote Sensing of Environment. 2009, č. 113, s. 835-845 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425708003702>>.

HÁJEK, F.; SVOBODA, M. (2007): *Vyhodnocení odumírání horského smrkového lesa na Trojmezí (NP Šumava) metodou automatizované klasifikace leteckých snímků* [online]. Silva Gabreta. 2007, č. 13, s. 69-81 [cit. 2013-02-21]. Dostupné z URL: <[http://www.npsumava.cz/storage/vyzkum/SGpdf/SG13\\_1\\_HajekSvoboda.pdf](http://www.npsumava.cz/storage/vyzkum/SGpdf/SG13_1_HajekSvoboda.pdf)>.

HALOUNOVÁ, L. (2002): *Zkušenosti s programem eCognition pro klasifikaci urbanizovaného území z leteckých černobílých snímků a snímků* [online]. Fakulta stavební ČVUT Praha. 2002 [cit. 2013-02-21]. Dostupné z URL: <[http://gis.vsb.cz/GIS\\_Ostrava/GIS\\_Ova\\_2002/Sbornik/Referaty/halounova3.htm](http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2002/Sbornik/Referaty/halounova3.htm)>.

HEALEY, S. P. (2005): *Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection* [online]. Remote Sensing of Environment. 2005, č. 97, s. 301-310 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425705001586>>.



HESSLEROVÁ, P.; KUČERA, T. (2006): *Krajina - známá neznámá. 2. Procesy v krajině* [online]. Ochrana přírody. 2006, č. 7, s. 195-198 [cit. 2013-02-21]. Dostupné z URL: <<http://www.casopis.ochranaprirody.cz/res/data/003/000487.pdf>>.

HICKE, J. A.; LOGAN, J. (2009): *Mapping whitebark pine mortality caused by a mountain pine beetle outbreak with high spatial resolution satellite imagery* [online]. International Journal of Remote Sensing. 2009, roč. 30, č. 70, s. 4427-4441 [cit. 2013-02-21]. Dostupné z URL: <[http://gis.fs.fed.us/wwetac/publications/hicke\\_logan\\_2009.pdf](http://gis.fs.fed.us/wwetac/publications/hicke_logan_2009.pdf)>.

HOFMANN, P.; STROBL, J.; BLASCHKE, T. (2008): *A method for adapting global image segmentation methods to images of different resolutions* [online]. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2008 [cit. 2011-1-7]. Dostupné z URL: <[http://homepages.ualg.ac/~gjhay/geobia/Proceedings/Sessions/Session5/6786\\_Hofmann\\_Proc\\_pap.pdf](http://homepages.ualg.ac/~gjhay/geobia/Proceedings/Sessions/Session5/6786_Hofmann_Proc_pap.pdf)>.

HUDAK, A. T. ...[et al.] (2002): *Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height* [online]. Remote Sensing of Environment. 2002, č. 82, s. 397-416 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425702000561>>.

HYDE, P. ...[et al.] (2006): *Mapping forest structure for wildlife habitat analysis using multi-sensor (LiDAR, SAR/InSAR, ETM+, Quickbird) synergy* [online]. Remote Sensing of Environment. 2006, č. 102, s. 63-73 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425706000551>>.

HYYPÄ, J. ...[et al.] (2001): *Algorithms and methods of airborne laser scanning for forest measurements* [online]. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. 2001, roč. 36, č. 8, s. 82-89 [cit. 2013-02-21]. Dostupné z URL: <[http://www.google.cz/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CDgQFjAA&url=http%3A%2F%2Fwww.researchgate.net%2Fpublication%2F228723758\\_Algorithms\\_and\\_methods\\_of\\_airborne\\_laserscanning\\_for\\_forest\\_measurements%2Ffile%2F9fcfd50b298a21d963.pdf&ei=TAOOUZb\\_GYf54QSvpIGgDA&usg=AFQjCNF-qo1CZa6vD\\_6UhUANaQEr5YvUg&sig2=3Ic9n026c6S16Vo3Htl6tw&bvm=bv.46340616,d.bGE](http://www.google.cz/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CDgQFjAA&url=http%3A%2F%2Fwww.researchgate.net%2Fpublication%2F228723758_Algorithms_and_methods_of_airborne_laserscanning_for_forest_measurements%2Ffile%2F9fcfd50b298a21d963.pdf&ei=TAOOUZb_GYf54QSvpIGgDA&usg=AFQjCNF-qo1CZa6vD_6UhUANaQEr5YvUg&sig2=3Ic9n026c6S16Vo3Htl6tw&bvm=bv.46340616,d.bGE)>.

JIN, S.; SADER, S. A. (2005): *Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances* [online]. Remote Sensing of Environment. 2005, č. 94, s. 364-372 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425704003414>>.

KAHUDA, P. (2011): *Lesy Národního parku Šumava - Vývoj a aktuální stav* [online]. Lesnická práce: časopis pro lesnickou vědu a praxi. 2011, č. 9 [cit. 2013-02-21]. Dostupné z URL: <<http://www.silvarium.cz/lesnicka-prace-c-9-11/lesy-narodniho-parku-sumava-vyvoj-a-aktualni-stav>>.

KE, Y.; QUACKENBUSH, L. J.; IM, J. (2010): *Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification* [online]. Remote Sensing of Environment. 2010, č. 114, s. 1141-1154 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425710000246>>.

KINDLMANN, P.; MATĚJKA, K.; DOLEŽAL, P. (2012): *Lesy Šumavy, lýkožrout a ochrana přírody*. 1. vyd. Praha: Karolinum. 2012, 325 s. ISBN: 978-80-246-2155-5.

KOLÁŘ, J.; HALOUNOVÁ, L.; PAVELKA, K. (1997): *Dálkový průzkum Země* 10. 1. vyd. Praha: Vydavatelství ČVUT. 1997, 164 s. ISBN: 80-01-01567-X.

KOMRSKA, V. (2006): *Detekce městské vegetace s využitím objektově orientované klasifikace*. Diplomová práce. Katedra aplikované geoinformatiky a kartografie PřF UK, Praha, 86 s.

KOŠULIC, M. (2009): *Disturbance neboli narušení* [online]. Přírodě blízké lesnictví: alternativní internetový lesnický časopis [cit. 2013-04-06]. Dostupné z URL: <<http://prirozenelesy.cz/node/26>>.

KUČERA, A. (2009): *Stav a management lesních ekosystémů v NP Šumava* [online]. Sborník příspěvků z workshopu konaného v Krkonošském národním parku [cit. 2013-04-01]. Dostupné z URL: <[http://www.mzp.cz/C1257458002F0DC7/cz/news\\_100125\\_management%20lesu/\\$FILE/Management%20les%C5%AF%20NP%20v%20%C4%8CR.pdf](http://www.mzp.cz/C1257458002F0DC7/cz/news_100125_management%20lesu/$FILE/Management%20les%C5%AF%20NP%20v%20%C4%8CR.pdf)>.

KUSHWAHA, S. P. S. (2012): *Remote Sensing and GIS for Forest Monitoring and Management* [online]. Enviro News: newsletter of ISEB India. 2012, roč. 18, č. 4 [cit. 2013-02-21]. Dostupné z URL: <<http://isebindia.com/09-12/12-10-01.html>>.

LILLESAND, T. M., KIEFER, R. W. (1994): *Remote sensing and image interpretation*. 3rd ed. New York: Wiley, 1994. 750 s. ISBN: 0-471-57783-9.

LIM, K. ...[et al.] (2003): *LiDAR remote sensing of forest structure* [online]. Progress in Physical Geography. 2003, č. 27, s. 88-106 [cit. 2013-02-21]. Dostupné z URL: <<http://ppg.sagepub.com/content/27/1/88.short>>.

LIU, Z. J.; WANG, J.; LIU, W. P. (2005): *Building extraction from high resolution imagery based on multi-scale object oriented classification and probabilistic Hough transform* [online]. International Geoscience and Remote Sensing Symposium. 2005 [cit. 2013-02-21]. Dostupné z URL: <[http://www.ecognition.com/sites/default/files/247\\_igarsslui.pdf](http://www.ecognition.com/sites/default/files/247_igarsslui.pdf)>.

LIZARAZO, I.; ELSNER, P. (2002): *Segmentation of Remotely Sensed Imagery: Moving from Sharp Objects to Fuzzy Regions* [online]. Image Segmentation. 2011 [cit. 2013-02-21]. Dostupné z URL: <<http://www.intechopen.com/books/image-segmentation/segmentation-of-remotely-sensed-imagery-moving-from-sharp-objects-to-fuzzy-regions>>.

MEDDENS, A. J. H.; JEFFREY, A. H.; VIERLING, L. A. (2011): *Evaluating the potential of multispectral imagery to map multiple stages of tree mortality* [online]. Remote Sensing of Environment. 2011, č. 115, s. 1632-1642 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S003442571100068X>>.

MEDDENS, A. J. H. ...[et al.] (2013): *Evaluating methods to detect bark beetle-caused tree mortality using single-date and multi-date Landsat imagery* [online]. Remote Sensing of Environment. 2013, č. 132, s. 49-58 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425713000060>>.

MEINEL, G.; NEUBERT, M. A. (2004): *A comparison of segmentation programs for high resolution remote sensing data* [online]. International Archives of Photogrammetry and Remote Sensing. 2004, č. 35, s. 1097-1105 [cit. 2013-02-21]. Dostupné z URL: <[http://faculty.wvu.edu/wallin/envr442/pdf\\_files/meinel\\_and\\_neubert\\_2006.pdf](http://faculty.wvu.edu/wallin/envr442/pdf_files/meinel_and_neubert_2006.pdf)>.

Ministerstvo zemědělství (2010): *Zpráva o stavu lesa a lesního hospodářství České republiky v roce 2010*. Praha: Ministerstvo zemědělství, 2010. 128 s. ISBN 978-80-7084-995-8.

MORALES, R. M.; MIURA, T.; IDOL, T. (2008): *An assessment of Hawaiian dry forest condition with fine resolution remote sensing* [online]. Forest Ecology and Management. 2008, roč. 255, č. 7, s. 2524-2532 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0378112708000625>>.

MYINT, S. W. ...[et al.] (2011): *Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery* [online]. Remote Sensing of Environment. 2011, č. 115, s. 1145-1161 [cit. 2013-02-21]. Dostupné z URL: <[http://geodacenter.asu.edu/drupal\\_files/2011\\_Myint\\_et\\_al\\_Urban\\_Object.pdf](http://geodacenter.asu.edu/drupal_files/2011_Myint_et_al_Urban_Object.pdf)>.

OUYANG, Z. T. ...[et al.] (2011): *A comparison of pixel-based and object-oriented approaches to VHR imagery for mapping saltmarsh plants* [online]. Ecological Informatics. 2011, č. 6, s. 136-146 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S1574954111000057>>.

PCI Geomatics (2001): *PCI Author User's Guide: Version 8.2* [online]. Richmond Hill, Ontario, Canada. 2001 [cit. 2013-02-21]. Dostupné z URL: <[http://www.ucalgary.ca/appinst/doc/geomatica\\_v91/manuals/author.pdf](http://www.ucalgary.ca/appinst/doc/geomatica_v91/manuals/author.pdf)>.

POTÚČKOVÁ, M. (2012): *Objektově orientovaná klasifikace obrazových dat*. 2012, Přednášková prezentace ve formátu pdf.

SKUHRAVÝ, V. (2007): *Lýkožrout smrkový škůdce horských lesů* [online]. Lesnická práce: časopis pro lesnickou vědu a praxi [cit. 2013-03-01]. Dostupné z URL: <<http://www.silvarium.cz/lesnicka-prace-c-8-01/lykozrout-smrkovy-skudce-horskyh-lesu>>.

SOLBERG, S. ...[et al.] (2006): *Remote sensing of forest health* [online]. Natcan International Conference on Laser-Scanners for Forest and Landscape Assessment, Freiburg, 2004 [cit. 2013-02-21]. Dostupné z URL: <<http://www.isprs.org/proceedings/XXXVI/8-W2/SOLBERG.pdf>>.

SOLBERG, S. ...[et al.] (2007): *Testing remote sensing techniques for monitoring large scale insect defoliation* [online]. The Norwegian Forest and Landscape Institute, ForestSat 2007. Dostupné z URL: <[http://www.skogoglandskap.no/filearchive/solberg\\_et\\_al2.pdf](http://www.skogoglandskap.no/filearchive/solberg_et_al2.pdf)>.

Spot Image (2013): *SPOT satellite imagery* [online]. 2013 [cit. 2013-03-22]. Dostupné z URL: <<http://www.astrium-geo.com/en/143-spot-satellite-imagery>>.

ŠADIBOL, J.; CHUDÝ, F. (2013): *Panchromatické zaostrovanie multispektrálnych snímok na získavanie kvantitatívnych a kvalitatívnych informácií v oblasti lesníckeho mapovania* [online]. Zvolen, Katedra hospodárskej úpravy lesov a geodézie, Lesnícka fakulta. 2013 [cit. 2013-02-21]. Dostupné z URL: <[http://gis.vsb.cz/GIS\\_Ostrava/GIS\\_Ova\\_2013/sbornik/papers/gis2013508affc97d081.pdf](http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2013/sbornik/papers/gis2013508affc97d081.pdf)>.

ŠANTRŮČKOVÁ, H. (2010): *Co vyprávějí šumavské smrčiny*. Správa NP a CHKO Šumava. 2010, 156 s. ISBN: 978-80-87257-04-3.

TONOLLI, S. ...[et al.] (2011): *Fusion of airborne LiDAR and satellite multispectral data for the estimation of timber volume in the Southern Alps* [online]. Remote Sensing of Environment. 2011, č. 115, s. 2486-2498 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425711001817>>.

Trimble (2012): *eCognition Developer 8.8 User Guide*. Trimble Documentation, München, Germany. 264 s.

Trimble (2012): *eCognition Developer 8.8 Reference Book*. Trimble Documentation, München, Germany. 448 s.

VIJAYARAJ, V. (2004): *Quantitative analysis of pansharpened images* [online]. Optical Engineering. 2004, roč. 45, č. 4 [cit. 2013-02-21]. Dostupné z URL: <<http://dx.doi.org/10.1117/1.2195987>>.

WANG, W. (2009): *Satellite Remote Sensing of Forest Disturbances Caused by Hurricanes and Wildland fires* [online]. PhD Thesis. George Mason University. 2009 [cit. 2013-02-21]. Dostupné z URL: <[http://digilib.gmu.edu/dspace/bitstream/1920/4579/1/Wang\\_Wanting.pdf](http://digilib.gmu.edu/dspace/bitstream/1920/4579/1/Wang_Wanting.pdf)>.

WHITE, J. C. ...[et al.] (2005): *Detection of red attack stage mountain pine beetle infestation with high spatial resolution satellite imagery* [online]. Remote Sensing of Environment. 2005, č. 96, s. 340-351 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425705001033>>.

WULDER, M. A. ...[et al.] (2006): *Surveying mountain pine beetle damage of forests: A review of remote sensing opportunities* [online]. Forest Ecology and Management. 2006, č. 221, s. 27-41 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0378112705005736>>.

WULDER, M. A. ...[et al.] (2008): *Multi-temporal analysis of high spatial resolution imagery for disturbance monitoring* [online]. Remote Sensing of Environment. 2008, č. 112, s. 2729-2740 [cit. 2013-02-21]. Dostupné z URL: <>.

WULDER, M. A. ...[et al.] (2009): *Characterizing boreal forest wildfire with multi-temporal Landsat and LIDAR data* [online]. Remote Sensing of Environment. 2009, č. 113, s. 1540-1555 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425709000844>>.

WULDER, M. A. ...[et al.] (2012): *Lidar sampling for large-area forest characterization: A review* [online]. Remote Sensing of Environment. 2012, č. 121, s. 196-209 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425712000855>>.

YU, X. ...[et al.] (2004): *Automatic detection of harvested trees and determination of forest growth using airborne laser scanning* [online]. Remote Sensing of Environment. 2004, č. 90, s. 451-462 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425704000549>>.

ZAHRADNÍK, P.; KNÍŽEK, M. (2007): *Lýkožrout smrkový (Ips typographus)* [online]. Lesní ochranná služba. 2007 [cit. 2013-02-21]. Dostupné z URL: <<http://www.nejedlyasyn.com/products/letaky-vydavane-lesni-ochrannou-sluzbou-los-informace-o-skudcich-a-obrane-proti-nim/>>.

ZHAO, K. ...[et al.] (2011): *Characterizing forest canopy structure with lidar composite metrics and machine learning* [online]. Remote Sensing of Environment. 2011, č. 115, s. 1978-1996 [cit. 2013-02-21]. Dostupné z URL: <<http://www.sciencedirect.com/science/article/pii/S0034425711001118>>.

## SEZNAM POUŽITÝCH ZDROJŮ DAT

*ArcČR 500: Digitální geografická databáze* [cd-rom]. © 2003 Arcdata Praha, s. r. o.

*so11001282001* (Panchromatický snímek SPOT 5 z roku 2005). Poskytnutý mezinárodní iniciativou Planet Action.

*so11001282003* (Multispektrální snímek SPOT 5 z roku 2005). Poskytnutý mezinárodní iniciativou Planet Action.

*LT51920262010255KIS01* (Multispektrální snímek Landsat 5 TM z roku 2010) [online]. U. S. Geological Survey. Staženo dne 28. května z webových stránek <<http://edcsns17.cr.usgs.gov/NewEarthExplorer/>>.

*Archivní ortofoto České republiky barevné* [cd-rom]. Poskytnuto v bezplatném rozsahu pro studentské účely (45 mapových listů o velikosti 2,5 x 2 km). Data byla zapůjčena © Českým úřadem zeměměřickým a katastrálním.

*Základní báze geografických dat České republiky (ZABAGED®) – polohopis* [cd-rom]. Poskytnuto v bezplatném rozsahu pro studentské účely (10 mapových listů ZM 10). Data byla zapůjčena © Českým úřadem zeměměřickým a katastrálním.

*Data z leteckého laserového skenování* [cd-rom]. Poskytnuto v rozsahu pokrývající celé zájmové území (33 mapových listů o velikosti 2,5 x 2 km). Data byla zakoupena PřF UK od © Českého úřadu zeměměřického a katastrálního.

## SEZNAM PŘÍLOH

- Příloha 1: CD s elektronickou podobou práce
- Příloha 2: Přehledová mapa zájmového území v Národním parku Šumava
- Příloha 3: Snímek SPOT z roku 2005 s nelesními oblastmi vypuštěnými z klasifikace
- Příloha 4: Snímek Landsat z roku 2010 s nelesními oblastmi vypuštěnými z klasifikace
- Příloha 5: Přehled parametrů při generování DEM a DSM v programu E3De
- Příloha 6: Výsledný nDSM rastr získaný z dat leteckého laserového skenování
- Příloha 7: Obrazové ukázky zástupců jednotlivých klasifikačních tříd
- Příloha 8: Klasifikační báze vytvořená pro klasifikaci snímku SPOT z roku 2005
- Příloha 9: Klasifikační báze vytvořená pro klasifikaci snímku Landsat z roku 2010
- Příloha 10: Výsledek objektově orientované klasifikace družicového snímku SPOT
- Příloha 11: Výsledek objektově orientované klasifikace družicového snímku Landsat